

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI**  
**Programa de Pós-Graduação em Educação**  
**Arthur Machado França de Almeida**

**UTILIZAÇÃO DE MODELOS OCULTOS DE MARKOV E APRENDIZAGEM POR  
REFORÇO PARA DETECÇÃO DE ESTILOS DE APRENDIZAGEM DE  
ESTUDANTES EM SISTEMAS DE GESTÃO DE APRENDIZAGEM**

**Diamantina**  
**2018**



**Arthur Machado França de Almeida**

**UTILIZAÇÃO DE MODELOS OCULTOS DE MARKOV E APRENDIZAGEM POR  
REFORÇO PARA DETECÇÃO DE ESTILOS DE APRENDIZAGEM DE  
ESTUDANTES EM SISTEMAS DE GESTÃO DE APRENDIZAGEM**

Dissertação apresentada ao Programa de Pós-Graduação em Educação da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito para obtenção do título de mestre.

Orientador: Profa. Dra. Luciana Pereira de Assis  
Coorientador: Prof. Dr. Alessandro Vivas Andrade

**Diamantina  
2018**

Elaborado com os dados fornecidos pelo(a) autor(a).

A447u

Almeida, Arthur Machado França de

Utilização de modelos ocultos de Markov e aprendizagem por reforço para detecção de estilos de aprendizagem de estudantes em sistemas de gestão de aprendizagem / Arthur Machado França de Almeida, 2018.

98 p. : il.

Orientadora: Luciana Pereira de Assis

Coorientador: Alessandro Vivas Andrade

Dissertação (Mestrado Profissional – Programa de Pós-Graduação em Educação) - Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2018.

1. Estilos de aprendizagem. 2. Modelos ocultos de Markov.  
3. Aprendizagem por Reforço. 4. Sistemas de gestão de aprendizagem.  
I. Assis, Luciana Pereira de. II. Andrade, Alessandro Vivas. III. Título  
IV. Universidade Federal dos Vales do Jequitinhonha e Mucuri.

**CDD 374.4**

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM  
Bibliotecária Nádia Santos Barbosa, CRB6 – 3468/0.

**Arthur Machado França de Almeida**

**UTILIZAÇÃO DE MODELOS OCULTOS DE MARKOV E APRENDIZAGEM POR  
REFORÇO PARA DETECÇÃO DE ESTILOS DE APRENDIZAGEM DE  
ESTUDANTES EM SISTEMAS DE GESTÃO DE APRENDIZAGEM**

Dissertação apresentada ao Programa de Pós-Graduação em Educação da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito para obtenção do título de mestre.

Orientador: Profa. Dra. Luciana Pereira de Assis  
Coorientador: Prof. Dr. Alessandro Vivas Andrade

Data de aprovação: 19/10/2018.

---

Profa. Dra. Luciana Pereira de Assis  
PPGED - UFVJM

---

Prof. Dr. Alessandro Vivas Andrade  
PPGED - UFVJM

---

Prof. Dr. Cristiano Grijó Pitangui  
PPGED - UFSJ

---

Profa. Dra. Cláudia Beatriz Berti  
Departamento de Computação - UFVJM

Diamantina  
2018



A Ana Paula, Manu e Marco Antônio.





## **AGRADECIMENTOS**

Agradeço a Deus, que tem me iluminado ao longo de toda a vida. Nessa caminhada não poderia ser diferente.

Aos meus pais, Celso e Tânia, que sempre foram os grandes incentivadores dos meus estudos. Aos meus sogros, Lia e Odorico (In Memoriam), que tão bem me acolheram nos últimos anos e por terem sido meus segundos pais. A minha companheira Ana Paula e aos meus filhos Manuela e Marco Antônio, que foram a razão maior de prosseguir e realizar o sonho do mestrado. Aos meus amigos, vocês foram essenciais nessa caminhada.

Aos meus orientadores, Profa. Luciana Assis e Prof. Alessandro Vivas, pela oportunidade, paciência e ensinamentos. Aos membros de banca, Prof. Cristiano Pitangui e Profa. Cláudia Berti, pelas sugestões e contribuições.

À UFVJM, pelos agora 7 anos de estudos. Ao IFNMG, ambiente de trabalho e de grandes amizades, que prestou grande apoio ao longo dessa etapa.



“Não se faz escolha nenhuma, nem a de não escolher, como se não fosse nada. Não se passa pela história como se não fosse nada.” (Autor Desconhecido).



## RESUMO

Um dos maiores desafios na área da Educação à Distância é fornecer soluções tecnológicas que atendam aos estudantes de forma diferenciada. Os Ambientes Virtuais de Aprendizagem, embora auxiliem os professores e estudantes na realização dos cursos, não consideram as diferenças individuais de cada discente. Pesquisas apontam que considerar as diferenças dos estudantes, por intermédio dos Estilos de Aprendizagem, impacta positivamente no rendimento dos alunos ao longo do curso. Diante desse cenário, a identificação automática de Estilos de Aprendizagem dos estudantes nos Sistemas de Gestão de Aprendizagem é um importante tópico nas pesquisas da área de Tecnologia aplicada à Educação. O presente trabalho apresenta uma abordagem para identificação automática dos Estilos de Aprendizagem dos estudantes em Sistemas de Gestão de Aprendizagem. A abordagem proposta utiliza Modelos Ocultos de Markov para modelar os Estilos de Aprendizagem, o Algoritmo de Viterbi para inferi-los, e uma abordagem de Aprendizagem por Reforço para correção da detecção automática dos Estilos de Aprendizagem. Os resultados apontam uma taxa média de 91% de inferências corretas, demonstrando ser uma abordagem eficaz e promissora para a utilização em Sistemas de Gestão de Aprendizagem.

Palavras-chave: Estilos de Aprendizagem. Modelos Ocultos de Markov. Aprendizagem por Reforço. Sistemas de Gestão de Aprendizagem.



## **ABSTRACT**

One of the greatest challenges in the area of Distance Education is to provide technological solutions that meet students in a differentiated way. Virtual Learning Environments, while assisting teachers and students in the completion of courses, do not consider the individual differences of each student. Researches point out that considering student differences, through the Learning Styles, positively impacts students' performance throughout the course. Given this scenario, the automatic identification of students' Learning Styles in the Learning Management Systems is an important topic in the field of Technology applied to Education. The present work presents an approach for the automatic identification of the Learning Styles of students in Learning Management Systems. The proposed approach uses Hidden Markov Models to model Learning Styles, the Viterbi Algorithm for inferring them, and a Reinforcement Learning approach for correcting the automatic detection of Learning Styles. The results indicate an average rate of 91% of correct inferences, proving to be an effective and promising approach to use in Learning Management Systems.

**Keywords:** Learning Styles. Hidden Markov Model. Reinforcement Learning. Learning Management Systems.





## LISTA DE ILUSTRAÇÕES

Figura 1 – Abordagens do processo ensino-aprendizagem . . . . .	27
Figura 2 – Aprendizagem por processamento da informação . . . . .	30
Figura 3 – Ciclo de Aprendizagem de Kolb . . . . .	32
Figura 4 – As quatro escalas bipolares do MBTI . . . . .	33
Figura 5 – Dimensões do Modelo de Honey e Mumford . . . . .	36
Figura 6 – Dimensões do modelo FSLSM . . . . .	38
Figura 7 – Escala de Classificação do ILS . . . . .	39
Figura 8 – Sistemas Tutores Inteligentes - União de três diferentes disciplinas . . . . .	47
Figura 9 – Arquitetura Tradicional dos Sistemas Tutores Inteligentes . . . . .	48
Figura 10 – AIWBES - Origens e Principais Tecnologias . . . . .	49
Figura 11 – Modelo Oculto de Markov para a Dimensão Entrada do FSLSM . . . . .	58
Figura 12 – Modelo Oculto de Markov para a Dimensão Processamento . . . . .	69
Figura 13 – Inferências de EA para o estudante 9, por disciplina . . . . .	81
Figura 14 – Inferências de EA para o estudante 10, por disciplina . . . . .	81
Figura 15 – Inferências de EA para o estudante 4, por disciplina . . . . .	82



## LISTA DE TABELAS

Tabela 1 – Forças e fraquezas de cada estilo de aprendizagem do modelo de Honey e Mumford . . . . .	36
Tabela 2 – Matriz de transição de estados ocultos - HMM para determinação de EA na dimensão Entrada . . . . .	59
Tabela 3 – Matriz de emissão de estados observáveis - HMM para determinação de EA na dimensão Entrada . . . . .	59
Tabela 4 – Observações relativas à dimensão Percepção e seus respectivos valores . . .	70
Tabela 5 – Observações relativas à dimensão Processamento e seus respectivos valores	71
Tabela 6 – Observações relativas à dimensão Organização e seus respectivos valores . .	71
Tabela 7 – Inferência do EA Real para dimensão Processamento . . . . .	72
Tabela 8 – Inferência do EA Real para dimensão Percepção . . . . .	72
Tabela 9 – Inferência do EA Real para dimensão Organização . . . . .	73
Tabela 10 – Variação de escala para a dimensão Processamento . . . . .	74
Tabela 11 – Variação de escala para a dimensão Percepção . . . . .	74
Tabela 12 – Variação de escala para a dimensão Organização . . . . .	74
Tabela 13 – Matriz de observáveis sem conversão - Estudante 1, disciplina 2 . . . . .	75
Tabela 14 – Matriz de observáveis - Estudante 1, disciplina 2 . . . . .	75
Tabela 15 – Observações relacionadas ao segundo estudante . . . . .	79
Tabela 16 – Resultados: EA Real e EA Probabilístico de cada estudante . . . . .	82



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
1.1	Justificativa	23
1.2	Objetivos	23
1.3	Organização do Trabalho	24
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>25</b>
2.1	O Processo Ensino-Aprendizagem	25
2.2	Teorias de Aprendizagem: Teoria Behaviorista e Cognitivismo	26
2.2.1	Behaviorismo	26
2.2.2	Cognitivismo	29
2.2.2.1	Psicologia Cognitiva	29
2.3	Estilos de Aprendizagem	30
2.3.1	A Teoria da Aprendizagem Experimental de Kolb	31
2.3.2	Myers-Briggs Type Indicator	33
2.3.3	Modelo de Pask	34
2.3.4	Modelo de Honey e Mumford	35
2.3.5	Felder Silverman Learning Style Model - FSLSM	37
2.3.6	Críticas aos Estilos de Aprendizagem	39
2.4	Educação à Distância e as Tecnologias da Informação e Comunicação	41
2.4.1	Ambiente Virtual de Aprendizagem	42
2.4.2	Sistemas Hipermídia Adaptativa	44
2.4.3	Sistemas Tutores Inteligentes	46
2.4.4	Sistemas Educacionais Inteligentes e Adaptativos Baseados na Web	48
2.5	Deteção de Estilos de Aprendizagem	49
2.5.1	Questionários	50
2.5.2	Redes Bayesianas	51
2.5.3	Redes Neurais Artificiais	51
2.5.4	Árvore de Decisão	52
2.5.5	Algoritmo Genético	53
2.5.6	Aprendizagem por Reforço e Cadeias de Markov	53
2.5.7	Mineração de Dados Educacionais	54
2.5.8	Máquina de Vetores de Suporte	55
2.5.9	Lógica Fuzzy	55
2.5.10	Modelo Oculto de Markov	55
<b>3</b>	<b>ABORDAGEM PROPOSTA</b>	<b>57</b>

<b>3.1</b>	<b>Modelos Ocultos de Markov . . . . .</b>	<b>57</b>
<b>3.1.1</b>	<b>Primeiro Problema - Verossimilhança . . . . .</b>	<b>59</b>
<b>3.1.2</b>	<b>Segundo Problema . . . . .</b>	<b>60</b>
<b>3.1.3</b>	<b>Terceiro Problema . . . . .</b>	<b>62</b>
<b>3.2</b>	<b>Aprendizagem por Reforço . . . . .</b>	<b>63</b>
<b>3.3</b>	<b>Trabalhos Utilizados como Base para a Proposta . . . . .</b>	<b>64</b>
<b>3.4</b>	<b>Estrutura da Abordagem . . . . .</b>	<b>67</b>
<b>3.4.1</b>	<b>Cálculo do EA Real . . . . .</b>	<b>71</b>
<b>3.4.2</b>	<b>Criação das Matrizes de Estados Observáveis . . . . .</b>	<b>73</b>
<b>3.4.3</b>	<b>Abordagem por Reforço . . . . .</b>	<b>76</b>
<b>3.4.3.1</b>	<b>Simulação do Desempenho do Estudante . . . . .</b>	<b>76</b>
<b>3.4.3.2</b>	<b>Distância Entre Estilos de Aprendizagem . . . . .</b>	<b>77</b>
<b>3.4.3.3</b>	<b>Cálculo do Reforço . . . . .</b>	<b>77</b>
<b>3.4.4</b>	<b>Algoritmo Proposto . . . . .</b>	<b>77</b>
<b>4</b>	<b>RESULTADOS E VALIDAÇÃO DA PROPOSTA . . . . .</b>	<b>79</b>
<b>4.1</b>	<b>Base de Dados Utilizada . . . . .</b>	<b>79</b>
<b>4.2</b>	<b>Resultados Obtidos . . . . .</b>	<b>80</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>85</b>
<b>5.1</b>	<b>Contribuições . . . . .</b>	<b>85</b>
<b>5.2</b>	<b>Trabalhos Futuros . . . . .</b>	<b>86</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>87</b>

## 1 INTRODUÇÃO

A Educação à Distância (EaD) tem crescido mundialmente nos últimos anos. No Brasil, a realidade não é diferente, visto que a EaD é incentivada pela Lei de Diretrizes e Bases da Educação (BRASIL, 1996). Segundo dados do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), o número de cursos de graduação à distância no Brasil cresceu 571%, entre 2003 e 2006. Entre 2011 e 2014, esse número cresceu 213% (BITTENCOURT; MERCADO, 2014).

Com o advento da Internet, diversas ferramentas para uso coletivo surgiram. Na área da educação, os Sistemas de Gestão de Aprendizagem (Learning Management Systems - LMS) vieram revolucionar a Educação a Distância, disponibilizando diversos recursos que dão suporte ao processo de ensino-aprendizagem, auxiliando no seu planejamento, implantação e avaliação.

Os sistemas de gestão de aprendizagem fornecem grande apoio aos professores, auxiliando-os na autoria e realização de cursos online (DORÇA, 2012). Mas esses sistemas não consideram as diferenças individuais dos estudantes, fornecendo um suporte limitado aos usuários (GRAF; IVES *et al.*, 2010), pois o mesmo conteúdo e estratégia pedagógica são utilizados para todos os discentes.

No Anuário Brasileiro de Educação Aberta e a Distância (2006, 2007), são apresentados indicadores que contribuem para a evasão ou insatisfação dos alunos dos cursos EaD, onde se destacam: o material didático não foi agradável; curso/materiais didáticos eram difíceis; escassez de materiais didáticos; ausência de interação com outros alunos. Sendo assim, os materiais didáticos dos cursos EaD são, de certa forma, um dos fatores que contribuem para a evasão e insatisfação nessa modalidade de ensino.

Conforme Boström (2011), uma maneira de melhorar o desempenho do estudante é melhorando o ensino. Assim, se o sistema dá suporte para uma maior qualidade de ensino, bons resultados são alcançados. Todos nós temos preferências de aprendizagem que nos permitem aprender de forma mais eficaz (GILBERT; HAN, 1999).

Bandura, Azzi e Polydoro (2009) afirmam que todo indivíduo possui padrões pessoais que são utilizados para realizar qualquer atividade a ele apresentada. Assim, a aprendizagem é abordada de acordo com um padrão pessoal desenvolvido pelo próprio indivíduo, fruto de suas interações e experiências. Sendo assim, existem diferenças na forma de cada pessoa aprender e compreendê-las pode ser o primeiro passo que as instituições de ensino devam dar rumo à aprendizagem eficaz (SILVA, 2012).

Considerar diferenças em relação aos estilos de aprendizagem, conhecimento prévio, habilidades cognitivas, interesses, motivação, dentre outras (BRUSILOVSKY; MILLÁN, 2007), tem um efeito importante na melhoria do progresso dos estudantes e nos resultados de aprendizagem (GRAF; IVES *et al.*, 2010). Diante desse cenário, a personalização torna-se a questão central para produzir Sistemas de Gestão de Aprendizagem adequados (DEVEDŽIĆ, 2006). Entretanto,

a maioria dos sistemas de ensino utiliza-se de páginas estáticas, o que leva esses ambientes a não aproveitarem as grandes possibilidades oferecidas por um processamento inteligente, para seleccionar e apresentar os conteúdos de aprendizagem (OLIVEIRA, 2006).

Dessa forma, um importante problema em pesquisas está relacionado ao desenvolvimento de sistemas que sejam capazes de fornecer adaptatividade, de acordo com as necessidades e características individuais de cada usuário. A adaptatividade é uma característica indispensável nestes sistemas, possibilitando o alcance de um grupo muito mais heterogêneo de estudantes (TSIRIGA; VIRVOU, 2004).

A introdução de adaptatividade nesses sistemas origina os chamados Sistemas Adaptativos e Inteligentes para Educação (SAIE), ou Sistemas Educacionais Inteligentes e Adaptativos baseados na Web (AIWBES - Adaptive and Intelligent Web-based Educational Systems) (BRUSILOVSKY, 2001a; BRUSILOVSKY; PEYLO, 2003). Esses sistemas, por meio da junção dos Sistemas Tutores Inteligentes e dos Sistemas de Hipermedia Adaptativa, personalizam a experiência educacional e, na medida em que se adaptam às características individuais de um estudante, tornam o processo de aprendizagem mais efetivo (BRUSILOVSKY, 2001a; BRUSILOVSKY; PEYLO, 2003).

Alguns teóricos e pesquisadores da educação consideram que os Estilos de Aprendizagem (EAs) compõem um fator importante no processo de aprendizagem, e concordam que incorporá-los ao processo de ensino tem grande potencial na facilitação da aprendizagem (GRAF; LIU *et al.*, 2009; DORÇA, 2012).

Por outro lado, trabalhos recentes tem questionado o uso de EA, pela dificuldade em detectá-los (VEENMAN; PRINS; VERHEIJ, 2003; RAWSON; STAHOVICH; MAYER, 2017) e pelo fato de muitos modelos para descrição de EAs possuírem aspectos determinísticos (KIRSCHNER; MERRIËNBOER, 2013; PASHLER *et al.*, 2008). Veremos, no entanto, que estes aspectos são considerados no presente trabalho.

Uma das maiores dificuldades na área educacional, relacionada à adaptação dos ambientes de aprendizagem, é a imprecisão na correta identificação dos EAs do estudante. As abordagens tradicionais para detecção de estilos de aprendizagem se mostram ineficientes, pois além da imprecisão, tem-se ainda o grau de incerteza associado a questionários para auto-avaliação de EA pelo estudante (GRAF; LIN *et al.*, 2007; PRICE, 2004).

Diante dessa dificuldade, as abordagens automáticas para modelagem do estudante surgem como alternativas. As abordagens automáticas são baseadas em algoritmos de aprendizado de máquina e inteligência artificial que conseguem detectar o EA. Elas são livres de ocorrência de auto concepções imprecisas ou inconsistentes (GRAF; LIU *et al.*, 2009). Além disso, permitem aos estudantes focarem somente na aprendizagem, sem a necessidade de informar explicitamente suas preferências. As abordagens automáticas tendem a ser mais precisas e menos suscetíveis a erros, já que permitem analisar dados resultantes de um intervalo de tempo, ao contrário de dados colhidos em um momento específico (DORÇA, 2012).



## 1.1 Justificativa

A Educação à Distância proporciona cada vez mais às pessoas a oportunidade de realizar seus estudos. Por meio da expansão das redes de acesso a dados, da rede mundial de computadores e da consequente criação e popularização do *e-learning*, o acesso a esse tipo de educação apresentou um enorme crescimento. Sendo assim, faz-se necessário que o processo ensino-aprendizagem na EaD seja constantemente estudado, revisado e aperfeiçoado.

Nesse processo de aperfeiçoamento e estudo, deve-se considerar que toda a EaD é dependente das Tecnologias da Informação e Comunicação e que professor e estudante estão separados fisicamente. Não existe, por exemplo, um professor que possa buscar melhorar sua didática e tornar o ensino mais atrativo para determinado estudante. As melhorias devem ser realizadas nos recursos tecnológicos existentes.

Sendo assim, uma das principais melhorias que vem sendo estudadas na área da EaD é a introdução da adaptatividade nos sistemas de gestão de aprendizagem. A introdução da adaptatividade, ao considerar os Estilos de Aprendizagem dos estudantes, tem como objetivo facilitar a aprendizagem e busca adaptar o ensino da instituição educacional ao aluno. No entanto, para a introdução da adaptatividade nesses sistemas é necessário conhecer o perfil dos estudantes, inclusive seus EAs.

A detecção dos estilos de aprendizagem deve ser dinâmica e automática, para evitar auto-concepções imprecisas (por meio de questionários) e para considerar os aspectos dinâmicos dos Estilos de Aprendizagem. Dessa forma, a presente pesquisa, ao apresentar uma abordagem para identificação automática de EAs, mostra-se relevante para a área educacional.

## 1.2 Objetivos

A presente pesquisa tem por objetivo propor e implementar uma abordagem eficiente para detecção automática e dinâmica de EA de estudantes em Sistemas de Gestão de Aprendizagem. A abordagem a ser implementada utilizará Modelos Ocultos de Markov para modelagem dos EAs dos estudantes e um algoritmo de Aprendizagem por Reforço para a correção dos EAs. O modelo utilizado para descrição de EA será o Felder-Silverman Learning Style Model.

Os objetivos específicos são:

- estudar, compreender e avaliar diferentes abordagens presentes na literatura para modelagem de estudante e detecção automática de estilos de aprendizagem;
- propor e implementar uma abordagem para detecção automática de estilos de aprendizagem, utilizando Modelos Ocultos de Markov;
- implementar um módulo que considere o aspecto dinâmico dos EAs e que faça eventuais correções no EA inferido;

- validar a abordagem, utilizando uma base de dados real com interações de alunos em um Sistema de Gestão de Aprendizagem.

### **1.3 Organização do Trabalho**

O restante deste trabalho está organizado da seguinte forma: no segundo capítulo, serão apresentados os aspectos teóricos para contextualização da proposta: fundamentos do processo ensino-aprendizagem, algumas teorias da aprendizagem e os principais modelos para descrição de EA presentes na literatura. Serão apresentados ainda alguns conceitos relativos à EaD e suas tecnologias, bem como uma revisão sobre os trabalhos relacionados à detecção de estilos de aprendizagem.

O terceiro capítulo apresenta os conceitos que embasam a abordagem que está sendo desenvolvida, bem como toda sua estrutura e modelagem. O quarto capítulo apresenta os resultados obtidos pela abordagem, bem como a base de dados utilizada para a validação do modelo proposto. Por fim, no quinto capítulo são apresentadas as considerações finais e algumas possibilidades de trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

Este capítulo busca fazer uma breve revisão bibliográfica, evidenciando alguns conceitos sobre os principais temas que servem como base para o bom entendimento do trabalho. Nesse sentido, no primeiro momento foram abordados os aspectos principais do processo ensino-aprendizagem, inclusive no que tange às teorias da aprendizagem (Behaviorismo e Cognitivismo), até chegar aos estilos de aprendizagem e seus modelos mais conhecidos.

No segundo momento, foram abordadas questões importantes sobre a EaD e as tecnologias que permitem que esse tipo de ensino ocorra. Dessa forma, foram abordadas as questões sobre os Ambientes Virtuais de Aprendizagem e seus problemas, bem como os Sistemas Hipermídia Adaptativa, Sistemas Tutores Inteligentes e os Sistemas Educacionais Inteligentes e Adaptativos Baseados na Web. Foi realizado um paralelo entre esses sistemas e, na medida do possível, eles foram diferenciados em termos de arquitetura e objetivos.

No terceiro momento, foram abordados aspectos relacionados à detecção automática de estilos de aprendizagem. Ainda, foram apresentados diferentes métodos existentes na literatura para a detecção de estilos de aprendizagem.

### 2.1 O Processo Ensino-Aprendizagem

A educação é um processo de desenvolvimento da personalidade do indivíduo, dentro de um contexto de relações sociais, que envolve a formação de qualidades morais, intelectuais, humanas e estéticas (LIBÂNEO, 1994). Ela é um processo social, onde a sociedade integra novos membros (SILVA, 2006). O que se entende atualmente como educação é uma grande compilação de pesquisas que incluem diversas áreas do conhecimento (SILVA, 2006).

A educação ocorre por meio de diversos fatores. Destaca-se como elemento crucial no âmbito educacional o processo ensino-aprendizagem. O ensino é a atividade educacional que permite ao indivíduo a apropriação de conhecimentos e saberes (SILVA, 2006). Já a aprendizagem é o processo cognitivo onde o indivíduo adquire conhecimentos e torna-se apto a interagir com o mundo (SILVA, 2006). Sendo assim, enquanto no ensino as atividades são centralizadas no professor e nas suas qualidades e habilidades, na aprendizagem as atividades estão concentradas no aluno e em suas capacidades, possibilidades e oportunidades (SILVA, 2006).

A aprendizagem é um processo que permite ao indivíduo modificar seu comportamento, sendo que essas modificações não se repetem diante de novas situações (OLIVEIRA; CHADWICK, 1984). Kolb, Boyatzis e Mainemelis (1984) definem a aprendizagem conforme uma abordagem experimental, considerando-a como um processo que sofre transformação de acordo com as experiências vividas, e que resulta em conhecimento.

No âmbito da educação, a aprendizagem é estruturada por duas etapas distintas (GRANITO, 2008):

- **Recepção:** nessa fase, as informações externas, obtidas pelos órgãos sensoriais, e internas, obtidas de modo introspectivo, são selecionadas.
- **Processamento da informação:** nessa fase, diversos fatores são considerados, como memorização, raciocínio, reflexão e ação, introspecção, interação entre indivíduos.

O aluno é parte fundamental do processo de aprendizagem. Ensinar e aprender são realidades diferentes, e apenas parte do que é ensinado ao aluno constitui de fato em aprendizagem (BORDENAVE; PEREIRA, 2014). Sendo assim, muitos dos problemas enfrentados no processo ensino-aprendizagem estão relacionados ao próprio ensino, não somente à aprendizagem e aos alunos (BORDENAVE; PEREIRA, 2014). Por isso torna-se extremamente importante uma criteriosa análise do processo de ensino, com o objetivo de melhorá-lo e torná-lo mais eficiente.

O processo de ensino-aprendizagem pode ser explicado segundo algumas abordagens teóricas. Em seu trabalho, Santos (2003) agrupa e sistematiza algumas dessas abordagens que foram detalhadas por Mizukami (1986), a saber: abordagem tradicional, abordagem comportamentalista, abordagem humanista, abordagem cognitivista e abordagem sócio-cultural. As abordagens e seus detalhes podem ser vistos na Figura 1.

Mizukami (1986) alerta que a compreensão do fenômeno educativo só acontece com a reflexão sobre os seus aspectos: é um fenômeno humano, histórico e multidimensional, onde estão presentes a dimensão humana, técnica, cognitiva, emocional, sócio-política e cultural. Sendo assim, o fenômeno educativo pode ser entendido como um projeto que se encontra permanentemente em construção e que possui diferentes causas e efeitos, de acordo com a dimensão focalizada (SANTOS, 2003).

## 2.2 Teorias de Aprendizagem: Teoria Behaviorista e Cognitivismo

As teorias da aprendizagem são princípios básicos que buscam organizar, interpretar e fazer previsões sobre conhecimentos relacionados à aprendizagem (MOREIRA, 1999). Mais do que a utilização em sala de aula, as teorias da aprendizagem são a base para construção de agentes para o ensino baseado no computador (FRAGELLI, 2011). Sendo assim, o estudo das teorias de aprendizagem são essenciais quando se pretende construir agentes que atuarão no ensino baseado na web.

Nas subseções seguintes serão abordadas duas teorias, consideradas como extremamente relevantes na literatura: o Behaviorismo e o Cognitivismo.

### 2.2.1 Behaviorismo

O Behaviorismo busca explicar o comportamento humano e, por isso, ele é conhecido também como comportamentalismo. As teorias behavioristas estudam o que os indivíduos fazem e que pode ser observado (MOREIRA, 1999), buscando uma relação entre os estímulos do

Figura 1 – Abordagens do processo ensino-aprendizagem

Abordagens	Abordagem Tradicional	Abordagem Comportamentalista	Abordagem Humanista	Abordagem Cognitivista	Abordagem Sócio-Cultural
<b>A Escola</b>	Lugar ideal para a realização da educação. Organizada com funções claramente definidas. Normas disciplinares rígidas. Preparar os indivíduos para a sociedade.	Uma agência educacional. Modelo empresarial aplicado à escola. Divisão entre planejamento (quem planeja) e execução (quem executa). No limite, a sociedade poderia ser sem escola. Uso da tele-educação. Ensino à distância.	Escola proclamada para todos "Democrática". Afrouxamento das normas disciplinares. Deve oferecer condições ao desenvolvimento e autonomia do aluno.	Dar condições para que o aluno possa aprender por si próprio. Oferecer liberdade de ação real e material. Reconhecer a prioridade psicológica da inteligência sobre a aprendizagem. Promover um ambiente desafiador favorável à motivação intrínseca do aluno.	Deve ser organizada e funcionar bem para proporcionar os meios para que a educação se processe em seus múltiplos aspectos.
<b>O Aluno</b>	O aluno é um ser "passivo" que deve assimilar os conteúdos transmitidos pelo professor. O aluno deve dominar o conteúdo cultural universal transmitido pela escola.	Elemento para quem o material é preparado. O aluno eficiente e produtivo é o que lida "cientificamente" com os problemas da realidade.	Um ser "ativo". Centro do processo de ensino e aprendizagem. Aluno criativo, que "aprendeu a aprender". Aluno participativo.	Papel essencialmente "ativo" de observar, experimentar, comparar, relacionar, analisar, justapor, compor, encaixar, levantar hipóteses, argumentar etc.	Uma pessoa concreta, objetiva, que determina e é determinada pelo social, político, econômico, individual (pela história). Deve ser capaz de operar conscientemente mudanças na realidade.
<b>O Professor</b>	É o transmissor dos conteúdos aos alunos. Predomina como autoridade.	É o educador que seleciona, organiza e aplica um conjunto de meios que garantam a eficiência e eficácia do ensino.	É o facilitador da aprendizagem.	Criar situações desafiadoras e desequilibradoras, através da orientação. Estabelecer condições de reciprocidade e cooperação ao mesmo tempo moral e racional.	É o educador que direciona e conduz o processo de ensino e aprendizagem. A relação professor e aluno deve ser horizontal, ambos se posicionam como sujeitos do ato de conhecimento.
<b>Ensino e Aprendizagem</b>	Os objetivos educacionais obedecem à sequência lógica dos conteúdos. Os conteúdos são baseados em documentos legais, selecionados a partir da cultura universal acumulada. Predominam aulas expositivas, com exercícios de fixação, leituras-cópias.	Os objetivos educacionais são operacionalizados e categorizados a partir de classificações: gerais (educacionais) e específicos (instrucionais). Ênfase nos meios: recursos áudio-visuais, instrução programada, tecnologias de ensino, ensino individualizado (módulos instrucionais), "máquinas de ensinar", computadores, hardwares, softwares. Os comportamentos desejados serão instalados e mantidos nos alunos por condicionantes e reforçadores.	Os objetivos educacionais obedecem ao desenvolvimento psicológico do aluno. Os conteúdos programáticos são selecionados a partir dos interesses dos alunos. "Não-diretividade". A avaliação valoriza aspectos afetivos (attitudes) com ênfase na auto-avaliação.	Desenvolver a inteligência, considerando o sujeito inserido numa situação social. A inteligência se constrói a partir da troca do organismo com o meio, através das ações do indivíduo. Baseado no ensaio e no erro, na pesquisa, na investigação, na solução de problemas, facilitando o "aprender a pensar". Ênfase nos trabalhos em equipe e jogos.	Os objetivos educacionais são definidos a partir das necessidades concretas do contexto histórico-social, no qual se encontram os sujeitos. Busca uma consciência crítica. O diálogo e os grupos de discussão são fundamentais para o aprendizado. Os "temas geradores" para o ensino devem ser extraídos da prática de vida dos educandos.

Fonte: Santos (2003).

ambiente e as respostas. O Behaviorismo é um termo criado por John Watson, considerado o pai da teoria.

Watson e seu Behaviorismo clássico foram fortemente influenciados por Ivan Pavlov e sua teoria do condicionamento clássico (FRAGELLI, 2011). O condicionamento clássico é um fenômeno descoberto por Pavlov em seus experimentos com cachorros. Nesse experimento, Pavlov colocava pó de carne na boca de um cão com o objetivo de mensurar a salivação do animal. Após algumas sessões, era detectado que o cão salivava apenas com a presença do cientista que conduzia o experimento (FRAGELLI, 2011).

Watson, juntamente com Rayner, foram os condutores do famoso Experimento do Pequeno Albert. O objetivo do experimento era demonstrar o funcionamento do condicionamento clássico de Pavlov em seres humanos. O controverso experimento foi realizado no bebê Albert, de apenas 11 meses. O experimento consistia na apresentação de um rato branco para a criança e, simultaneamente, um som alto e amedrontador (FRAGELLI, 2011). Após uma semana dos experimentos, o bebê se afastava e chorava apenas com a presença do rato branco (FRAGELLI, 2011). Watson queria reduzir o medo de Albert aos estímulos condicionados utilizando o processo de extinção estudado por Pavlov (WIER, 2005). No entanto, a mãe de Albert o retirou dos experimentos antes de sua conclusão (WIER, 2005).

A continuação do trabalho de Watson se deu com Mary Cover Jones, aluna de doutorado de Watson (WIER, 2005). O experimento de Jones foi com o pequeno Peter e o objetivo era eliminar o medo que a criança tinha de alguns animais. Foi constatado que em alguns casos, a criança superava o medo (WIER, 2005).

Outro grande pesquisador do Behaviorismo é Skinner, considerado como pai do Behaviorismo radical (FRAGELLI, 2011). O Behaviorismo radical se pautava pela objetividade dos fenômenos observáveis (SILVA, 2012). Nessa abordagem, são consideradas como variáveis de entrada apenas o estímulo, um reforço e as contingências de reforço (FRAGELLI, 2011). De acordo com Fragelli (2011), o estímulo é um evento que afeta os sentidos do indivíduo; o reforço aumenta a probabilidade de ocorrência de um comportamento que o precedeu; as contingências de reforço são um arranjo de uma situação em que a ocorrência de uma resposta que leve ao reforço se torne possível.

No âmbito educacional, Skinner defende que o papel do professor deve estar ligado às contingências de reforço, pois assim será possível realizar um planejamento em que o aprendiz tenha um comportamento desejável com mais probabilidade (FRAGELLI, 2011). Alguns fenômenos estudados por Skinner podem ser aplicados na área da educação, como é o caso da modelagem e do esmaecimento.

Na modelagem, as respostas intermediárias são reforçadas, tornando possível a criação de um comportamento final (FRAGELLI, 2011). Já no esmaecimento, alguns estímulos iniciais que possuem diferentes valores são apresentados ao aprendiz. Gradativamente, um deles é esmaecido, de forma a manter apenas o estímulo desejado (FRAGELLI, 2011).

### 2.2.2 Cognitivismo

Com a dificuldade em se explicar o comportamento humano utilizando apenas estímulos, respostas e reforço, os psicólogos acabaram tendo um desencantamento com o Behaviorismo (FRAGELLI, 2011). Isso abriu espaço para novas abordagens, como o cognitivismo. De acordo com Silva (2012), os estudos de alguns neobehavioristas, como Thorndike e Tolman, acabaram disseminando algumas críticas ao Behaviorismo, contribuindo para o surgimento do cognitivismo.

Em suas pesquisas, Edward L. Thorndike entendeu que a motivação é um fator que interfere na aprendizagem. Assim, toda ação causa um efeito satisfatório ou insatisfatório e aquelas ações que conduzem à satisfatoriedade tendem a ser repetidas e reforçadas, ao contrário daquelas insatisfatórias (SILVA, 2012). Thorndike definiu também a ideia de aprendizagem ideacional, um tipo de aprendizagem que requer análise, abstração e significação (SILVA, 2012).

Já Edward C. Tolman entende que o reforço não interfere na aprendizagem. Ele definiu cinco variáveis intervenientes que determinam o comportamento humano: estímulo ambiental, impulsos fisiológicos, hereditariedade, treinamento prévio e idade (SILVA, 2012). Tolman acreditava que os processos internos do organismo interferiam no comportamento do indivíduo e, por isso, ele é considerado um dos pioneiros da psicologia cognitiva (SILVA, 2012).

Como abordado, o cognitivismo surgiu como uma resposta ao Behaviorismo. De acordo com Moreira (1999), o cognitivismo propõe estudar processos mentais superiores, como a compreensão, percepção, atenção, memória, linguagem, tomada de decisão, entre outros processos intelectuais. Sendo assim, o cognitivismo busca se preocupar com outras variáveis, não somente com as associações entre estímulos e respostas, características do Behaviorismo. Para Fragelli (2011), a cognição busca descrever a aquisição, armazenamento, transformação e aplicação do conhecimento. Dentre os teóricos e pesquisadores da área do cognitivismo, destacam-se Tolman, Lewi, Hebb, Ausubel e Piaget.

#### 2.2.2.1 Psicologia Cognitiva

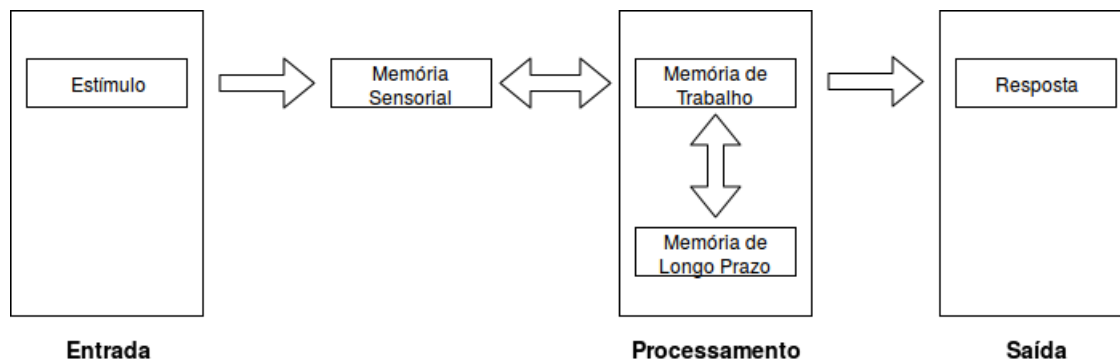
A psicologia cognitiva foi influenciada pela criação do computador e pela Teoria da Informação (SILVA, 2012). Isso porque na psicologia cognitiva, a aprendizagem é compreendida como um processo onde o indivíduo percebe, seleciona, manipula, significa e armazena as informações do ambiente (SILVA, 2012). Para Castañon (2007), o modelo computacional onde existe uma entrada, processamento e saída pode ser aplicado ao processo de aprendizagem, na medida em que ocorre a transformação da informação por meio do organismo humano, gerando uma saída/resposta.

Sendo assim, a aprendizagem por processamento da informação é caracterizada por uma entrada, processamento e saída. Mayer (1985) definiu um modelo para processamento da informação humana, que pode ser visualizado na Figura 2.

Mayer (1985) acreditava que os indivíduos possuem formas distintas de processar a



Figura 2 – Aprendizagem por processamento da informação



Fonte: Adaptado de Mayer (1985).

informação e que, portanto, existem diferenças na forma de aprender. Essas formas diferentes que os indivíduos possuem de aprender são conhecidas como estilos de aprendizagem.

### 2.3 Estilos de Aprendizagem

O processo ensino-aprendizagem, da forma como é concebido atualmente, é um processo homogêneo. Ou seja, em nenhum momento do processo considerada-se que as pessoas possuem formas diferentes de aprender, que são moldadas por suas características psicológicas. Por se tratar de um processo teoricamente igualitário, essa visão homogênea, em um primeiro momento, pode parecer mais justa (CAVELLUCCI *et al.*, 2003). No entanto, ao realizar a análise sob a visão didático-pedagógica, o processo de ensino-aprendizagem de forma homogênea é equivocado, visto que a forma de receber e assimilar o conhecimento são pessoais e individuais (SENA *et al.*, 2016). As diferentes formas como os indivíduos aprendem derivam de suas características psicológicas, e são conhecidas como estilos de aprendizagem.

Conhecer os estilos de aprendizagem dos estudantes pode ajudar de muitas maneiras a melhorar o processo ensino-aprendizagem, principalmente nos Ambientes Virtuais de Aprendizagem (GRAF; LIU *et al.*, 2009). Para Rosário *et al.* (2006), a diferença na forma de aprendizagem dos estudantes é, muitas vezes, responsável pelas reprovações e evasões nos cursos.

Existem diversas teorias que buscam explicar o que são os estilos de aprendizagem, a maioria delas com definições e conceitos bem distintos (SILVA, 2012). No entanto, todos os autores dessas teorias concordam que existem diferenças individuais na aprendizagem e que cada indivíduo reage de maneira diferente frente a determinado problema (SILVA, 2012).

Os estilos de aprendizagem (EA) são características básicas de como se aprende uma nova informação, e não são perceptíveis de forma consciente pelos estudantes (REID, 1998). Os EAs são características cognitivas que servem como um indicador de como o estudante percebe, interage e responde aos ambientes de aprendizagem (FELDER; BRENT, 2005).

Ao longo do tempo, diversos modelos foram desenvolvidos para a estruturação e



descrição de EA. Os modelos de estilos de aprendizagem servem para categorizar e classificar as diferentes formas de aprender, receber e processar as informações (ROSÁRIO *et al.*, 2006). De acordo com Coffield *et al.* (2004), existem mais de 70 modelos para explicar os estilos de aprendizagem. Nas subseções seguintes, serão abordados os principais modelos desenvolvidos para estruturação e descrição de EA.

### 2.3.1 A Teoria da Aprendizagem Experimental de Kolb

Um dos mais influentes modelos para descrição de EA foi desenvolvido por David Kolb. O modelo de Kolb se desenvolve considerando duas atividades de aprendizagem distintas: percepção (ou apreensão) e processo (ou transformação) (LIMA *et al.*, 2007).

A percepção é a interpretação dos estímulos recebidos por meio dos dispositivos sensoriais (KOLB; BOYATZIS; MAINEMELIS, 1984). Embora os dispositivos sensoriais sejam praticamente idênticos em todos os indivíduos, a interpretação dos estímulos, que ocorre por meio do cérebro, varia de indivíduo para indivíduo (LIMA *et al.*, 2007).

Após a percepção da informação, ocorre o processamento dessa informação (KOLB; BOYATZIS; MAINEMELIS, 1984). O processamento, assim como a percepção, varia de indivíduo para indivíduo. Enquanto alguns processam melhor a informação por intermédio de ações, outros preferem a observação e reflexão (LIMA *et al.*, 2007).

Combinando as diferentes formas de percepção e processamento da informação, Kolb elaborou o seu modelo, conhecido como Teoria da Aprendizagem Experimental (LIMA *et al.*, 2007). A Teoria da Aprendizagem Experimental de Kolb, Boyatzis e Mainemelis (1984) pressupõe que a aprendizagem inicia-se com uma Experiência Concreta que utiliza os sentidos e sentimentos. Essa etapa é seguida pela Observação Reflexiva, que utiliza das observações e reflexões. A terceira etapa do ciclo de aprendizagem é a Conceitualização Abstrata, que utiliza o raciocínio lógico. A última etapa do ciclo de aprendizagem de Kolb é a Experimentação Ativa, onde a aprendizagem ocorre por meio do paradigma "aprender fazendo".

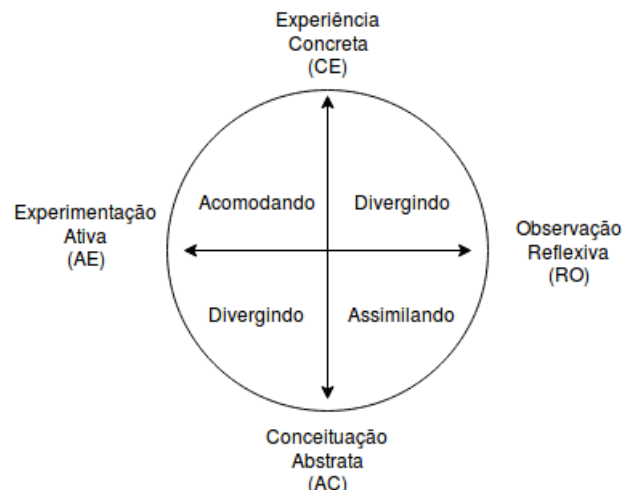
O modelo de Kolb é composto ainda por quatro dimensões, que podem ser assim descritas (COFFIELD *et al.*, 2004):

- Divergente: enfatiza a experiência concreta e a observação reflexiva. Os estudantes com esse perfil normalmente são imaginativos e conscientes de significados e valores e vêem as situações concretas sob muitas perspectivas. São interessados em pessoas.
- Assimilador: baseia-se na conceitualização abstrata e observação reflexiva. Os estudantes com esse perfil gostam de induções e criação de modelos teóricos, além de serem mais preocupados com ideias e conceitos abstratos do que com pessoas.
- Convergente: baseia-se principalmente na conceitualização abstrata e experimentação ativa. Os estudantes com esse perfil normalmente são bons na resolução de problemas, tomada de decisões e na aplicação prática de ideias. Preferem problemas técnicos do que lidar com problemas interpessoais.

- Acomodador: enfatiza as experiências concretas e experimentação ativa. Os estudantes com esse perfil gostam de fazer planos e se envolver em novas experiências, além de serem bem adaptáveis a mudanças. Ficam à vontade com as pessoas, mas algumas vezes podem ser vistos como impacientes.

O ciclo de aprendizagem de Kolb pode ser visto graficamente, conforme Figura 3.

Figura 3 – Ciclo de Aprendizagem de Kolb



Fonte: Adaptado de [Coffield et al. \(2004\)](#).

Para [Kolb, Boyatzis e Mainemelis \(1984\)](#), o aprendizado é o processo onde o conhecimento é criado por meio da transformação da experiência. Sendo assim, o conhecimento é a combinação da experiência adquirida e da transformação desta ([KOLB; BOYATZIS; MAINEMELIS, 1984](#)). A aprendizagem experimental possui, então, seis características principais ([COFFIELD et al., 2004](#)):

- A aprendizagem é melhor concebida como um processo, não como resultados.
- A aprendizagem é um processo contínuo, baseado na experiência.
- A aprendizagem requer a resolução de conflitos entre modos de adaptação opostos. Os modos de adaptação são os descritos na figura 3: experiência concreta, observação reflexiva, conceitualização abstrata e experimentação ativa. O aprendizado é, naturalmente, um processo carregado de tensão, já que o conhecimento novo é construído por estudantes que escolhem o tipo de habilidades que eles precisam. Os conflitos são resolvidos escolhendo um desses modos de adaptação.
- A aprendizagem é um processo holístico de adaptação ao mundo.
- A aprendizagem envolve transações entre a pessoa e o meio ambiente.
- A aprendizagem é o processo de criação do conhecimento, que resulta da transação entre conhecimento social e conhecimento pessoal.

Kolb elaborou ainda o LSI (Learning Style Inventory), que é uma ferramenta para identificação de estilos de aprendizagem dos indivíduos. O LSI é baseado na teoria de Kolb e já foi revisado diversas vezes, produzindo outras versões. No questionário, o indivíduo é instigado a responder doze sentenças que descrevem a aprendizagem, sendo que cada uma das sentenças apresenta quatro alternativas (COFFIELD *et al.*, 2004). Cada uma das alternativas diz respeito a um estilo de aprendizagem do modelo de Kolb.

O LSI é um instrumento amplamente utilizado. Até o ano de 1999, mais de 990 pesquisas utilizaram o questionário como instrumento para levantamento dos EA de estudantes (KOLB *et al.*, 2001).


### 2.3.2 Myers-Briggs Type Indicator

De acordo com Coffield *et al.* (2004), Katherine Cook Briggs e sua filha Isabel Briggs Myers desenvolveram um questionário psicométrico com o objetivo de descobrir as diferentes personalidades, segundo os tipos psicológicos de Carl Jung. Esse questionário ficou conhecido como Myers-Briggs Type Indicator - Indicador de Tipos de Myers-Briggs (MBTI).

Os tipos psicológicos de Carl Jung apresentam a ideia da existência de dois lados: um ligado à percepção, que utiliza as dimensões Sensação e Intuição; outro ligado ao julgamento de fatos, que utiliza as dimensões Pensamento e Sentimento (SENA *et al.*, 2016).

O questionário utiliza quatro escalas de personalidade: a primeira relacionada a Extroversão e Introversão; a segunda a Sensação e Intuição; a terceira relacionada a Pensamento e Sentimento; e por fim a quarta, relacionada a Julgamento e Percepção (ROSÁRIO *et al.*, 2006). Cada uma das quatro escalas (ou dimensões) apresenta duas subdimensões, conforme Figura 4.

Figura 4 – As quatro escalas bipolares do MBTI



Fonte: Adaptado de Coffield *et al.* (2004).

As subdimensões são assim caracterizadas (SENA *et al.*, 2016):

- Extroversão: o perfil é caracterizado pela sociabilidade. O estudante desse perfil se sente confortável na relação com outras pessoas e em exercer atividades em grupo.
- Introversão: o perfil é caracterizado pelo fechamento interno e dificuldade nas relações em grupo. O estudante desse perfil tem facilidade em atividades que exigem concentração.
- Sensação: o perfil é caracterizado pela personalidade sistemática e detalhista. O estudante desse perfil prefere as rotinas bem definidas.

- Intuição: o perfil é caracterizado pela facilidade com as ideias e desenvolvimento de inferências com base em conceitos previamente obtidos. O estudante desse perfil não gosta de rotinas bem definidas.
- Pensamento: o perfil se caracteriza pela racionalidade. O estudante desse perfil pauta suas decisões sempre pela lógica e geralmente são disciplinados e ansiosos.
- Sentimento: o perfil se caracteriza pela consciência social. O estudante desse perfil pauta suas decisões pela subjetividade e em benefício da coletividade.
- Julgamento: o perfil se caracteriza pela disciplina, planejamento das ações e comprometimento com os resultados. O estudante desse perfil dificilmente perde tempo com subjetividades e prefere processos rígidos e bem controlados.
- Percepção: o perfil se caracteriza pela flexibilidade e abertura à mudanças e novas experiências. O estudante desse perfil tem dificuldade com prazos rígidos e se adapta melhor à mudanças de planos.

As quatro dimensões, por meio de suas duas subdimensões, são combinadas produzindo dezesseis diferentes combinações que identificam o EA do estudante.

### 2.3.3 Modelo de Pask

Em seu trabalho, [Pask \(1976\)](#) argumenta que existem diferenças identificáveis entre as estratégias dos estudantes. Alguns alunos tendem a adotar uma estratégia holística, que visa construir uma ampla visão da tarefa e a relacionar esta com a vida real e as experiências pessoais ([COFFIELD et al., 2004](#)). Já outros alunos tendem a adotar uma estratégia serialista, onde a compreensão é construída a partir dos detalhes das atividades, dos fatos e resultados experimentais ([COFFIELD et al., 2004](#)).

De acordo com [Pask \(1976\)](#), existem duas formas de estratégias de aprendizagem, que são assim caracterizados ([COFFIELD et al., 2004](#)):

- Holístico: tende a formular hipóteses mais complexas relacionadas a mais de uma característica por vez.
- Serialista: procedimento de aprendizagem passo a passo, com hipóteses simples e relacionadas a uma mesma característica.

Dessa forma, os estudantes serialistas tendem a abordar um assunto passo a passo, indo do conhecido ao desconhecido e utilizando links simples entre os itens do conhecimento ([OTERO et al., 2008](#)). Os estudantes holistas tendem a organizar um esquema geral e depois explorá-lo com uma maior organização ([OTERO et al., 2008](#)).

Com essa distinção entre holísticos e serialistas, Pask identificou algumas "patologias" relacionadas a cada uma das características ([COFFIELD et al., 2004](#)). Os holísticos, por

exemplo, costumam procurar por analogias mais ricas e fazem links inapropriados entre ideias, problema conhecido como 'globetrotting'; já os serialistas costumam ignorar analogias válidas, conhecido como 'improvidence' (COFFIELD *et al.*, 2004).

A partir de sua teoria e de resultados realizados com máquinas de ensino, Pask propôs a sua Teoria da Conversação, que propõe uma discussão no processo ensino-aprendizagem (OTERO *et al.*, 2008). A Teoria da Conversação tem como principal objetivo explicar como ocorre o processo de aprendizagem nas máquinas e nos seres vivos (OTERO *et al.*, 2008).

#### 2.3.4 Modelo de Honey e Mumford

Os estudos de Alan Mumford iniciaram-se no final da década de 1970, quando este foi encarregado de uma gerência sênior na organização em que trabalhava. Ele convidou o psicólogo Peter Honey para estudar o aprendizado dos gerentes de organizações (COFFIELD *et al.*, 2004). Inicialmente eles começaram utilizando o Learning Style Inventory (LSI) de Kolb. No entanto, o LSI de Kolb não apresentou muita validade ao ser utilizado com gerentes (COFFIELD *et al.*, 2004). Após alguns anos de pesquisas, eles desenvolveram o Learning Styles Questionnaire (LSQ).

Enquanto o LSI de Kolb pergunta diretamente ao indivíduo como eles aprendem, o questionário de Honey e Mumford busca analisar as tendências comportamentais gerais daquele que está sendo arguido (COFFIELD *et al.*, 2004).

Honey e Mumford (1992) definem EA como a descrição de atitudes e comportamentos do estudante que estabelecem a sua forma preferida de aprendizagem. Com base nessa definição e em todos os estudos realizados, foram elencados quatro estilos de aprendizagem para os indivíduos: ativo, reflexivo, teórico e pragmático (HONEY; MUMFORD, 1992). Esses estilos estão fortemente conectados à versão revisada do ciclo de aprendizagem de Kolb (COFFIELD *et al.*, 2004). Os próprios autores já explicitaram a relação e a dívida que possuem com o LSI e a teoria de Kolb.

Para Honey e Mumford (1992), em cada estudante é possível identificar características de vários desses estilos. No entanto, sempre existe um estilo dominante. Cada um dos quatro estilos definidos por Honey e Mumford possuem suas forças e fraquezas, e os pontos fortes podem ser importantes em determinada situação, em outras não (COFFIELD *et al.*, 2004). Os pontos fortes e fracos de cada um dos estilos de aprendizagem do modelo proposto por Honey e Mumford (1992) podem ser vistos na Tabela 1.

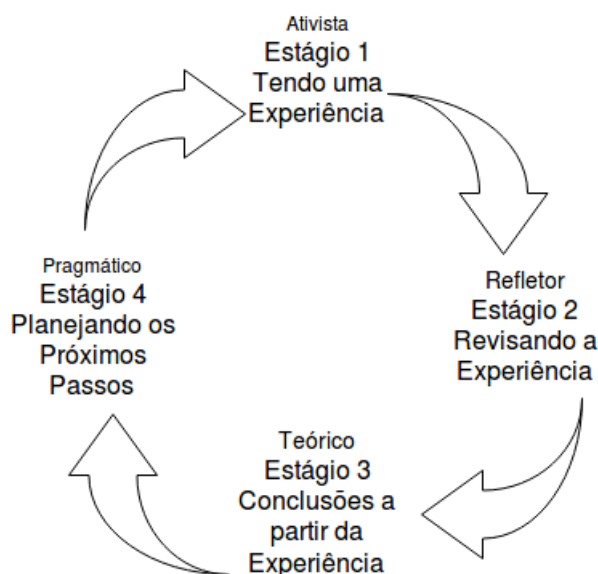
As dimensões do modelo de Honey e Mumford podem ser entendidas como um ciclo de aprendizagem e, conforme já dito, originam do modelo revisado de Kolb. Sendo assim, os ativos tem uma predisposição para experiências; os reflexivos para revisar experiências; os teóricos para tirar conclusões a partir de experiências; já os pragmáticos para planejamento dos próximos passos (COFFIELD *et al.*, 2004). O ciclo de aprendizagem do modelo pode ser visto graficamente, conforme Figura 5.

Tabela 1 – Forças e fraquezas de cada estilo de aprendizagem do modelo de Honey e Mumford

<b>Estilo</b>	<b>Forças</b>	<b>Fraquezas</b>
Ativo	Flexível e com mente aberta; pronto para agir e responder a determinadas situações; gosta de ser exposto a novas situações; otimista no que diz respeito à mudanças.	Tendência em tomar uma decisão óbvia sem avaliar as possíveis consequências; sofre riscos desnecessários com frequência; tendem a ser o centro das atenções; realizam ações sem o devido preparo.
Reflexivo	Cuidadoso, metódico, pensativo; bom em ouvir outros indivíduos e assimilar as informações; raramente toma conclusões precipitadas.	Evita a participação direta; lento para tomar alguma decisão; por ser cauteloso, não corre riscos suficientes; geralmente não é assertivo.
Teórico	Lógico, racional e objetivo; bom em realizar sondagens por meio de perguntas; possui uma abordagem disciplinada.	Possui baixa tolerância a incerteza, desordem e ambiguidade; intolerante com coisas subjetivas ou intuitivas.
Pragmático	Ansioso para testar as coisas na prática; prático e realista; orientado a técnicas.	Tendência a rejeitar coisas sem aplicação óbvia; não é interessado em teorias ou princípios básicos; são impacientes com indecisões; tendem a utilizar a primeira solução encontrada para determinado problema; são mais orientados para tarefas do que para pessoas.

Fonte: Adaptado de [Honey e Mumford \(2000\)](#)

Figura 5 – Dimensões do Modelo de Honey e Mumford



Fonte: Adaptado de [Coffield et al. \(2004\)](#).

O trabalho de Honey e Mumford é importante, também, por conseguir prover algumas respostas a questões importantes relacionadas a EA, como (COFFIELD *et al.*, 2004):

- Existem somente quatro estilos de aprendizagem? - Os quatro estilos representam os estágios que as pessoas precisam passar para se tornar estudantes equilibrados e são amplamente entendidos, aceitos e usados pelos estudantes (HONEY; MUMFORD, 2000).
- As preferências de estilos de aprendizagem podem mudar? - Devido a uma mudança de circunstância ou para fortalecer algum estilo subdesenvolvido, as preferências podem mudar. Por exemplo, a mudança de emprego para uma empresa com cultura diferente pode ocasionar a mudança de alguma preferência (HONEY; MUMFORD, 2000).
- Quão precisas são as auto-percepções? - As auto-percepções podem ser enganosas. Além disso, as respostas são fáceis de falsificar quando o indivíduo que está respondendo o questionário estiver determinado a causar uma impressão enganosa (HONEY; MUMFORD, 2000).

O LSQ, questionário criado por Honey e Mumford, já foi revisado diversas vezes. A versão atual do LSQ contém 80 itens, sendo 20 itens para cada um dos quatro estilos de aprendizagem do modelo proposto por Honey e Mumford (COFFIELD *et al.*, 2004). O modelo e o questionário LSQ são amplamente utilizados no meio empresarial.

### 2.3.5 Felder Silverman Learning Style Model - FSLSM

De acordo com Felder, Silverman *et al.* (1988), os EA são características e preferências na forma como as pessoas recebem, organizam e processam as informações. A aprendizagem, segundo Felder, Silverman *et al.* (1988), depende não somente da capacidade e preparação do aluno, mas também da correspondência entre seu estilo de aprendizagem e o estilo de ensino do professor.

A partir dessas definições e no desenvolvimento das pesquisas, Felder, Silverman *et al.* (1988) criaram o Felder-Silverman Learning Style Model - FSLSM. De acordo com Liu, Graf *et al.* (2009), o FSLSM se destaca pelo fato de combinar alguns dos principais modelos para descrição de EA, como Kolb, Boyatzis e Mainemelis (1984), Pask (1976) e Myers, McCaulley e Most (1985).

Em sua primeira versão, o FSLSM era composto por cinco dimensões de EA. As dimensões correspondiam à preferência do estudante em perceber (sensorial/intuitivo), reter (visual/auditivo), organizar (indutivo/dedutivo), processar (ativo/reflexivo) e compreender a informação (sequencial/global) (SILVA, 2012).

O modelo foi revisado e, atualmente, o FSLSM (FELDER; SILVERMAN *et al.*, 1988) é baseado em 4 dimensões: entrada, percepção, processamento e organização. Cada uma das dimensões é dividida em duas subdimensões, conforme Figura 6.



Figura 6 – Dimensões do modelo FSLSM

<b>Percepção</b> Sensitivo ou Intuitivo	<b>Entrada</b> Visual ou Verbal
<b>Processamento</b> Ativo ou Reflexivo	<b>Organização</b> Sequencial ou Global

Fonte: Adaptado de [Felder, Silverman \*et al.\* \(1988\)](#).

As dimensões e subdimensões se caracterizam da seguinte forma ([DORÇA, 2012](#); [SILVA, 2012](#); [FELDER; SILVERMAN \*et al.\*, 1988](#); [FELDER; BRENT, 2005](#); [GRANITO, 2008](#)):

- Entrada: essa dimensão refere-se ao tipo de informação que é mais efetivamente percebida. Aponta quais sensores são mais utilizados na recepção da informação. Subdivide-se em:
  - Visual: a preferência é por figuras, diagramas, gráficos, filmes.
  - Verbal: a preferência é por explicação escrita ou falada. Apresentam boa memória auditiva.
- Percepção: essa dimensão refere-se ao tipo de informação que o estudante prefere receber. Indica como o estudante percebe o ambiente em que está inserido. Subdivide-se em:
  - Sensitivo: a preferência é por fatos, datas, dados experimentais, exemplos. Os estudantes desse estilo são pacientes com os detalhes.
  - Intuitivo: a preferência é por teorias, definições, modelos matemáticos, símbolos e diagramas. Possuem como ponto forte a abstração. São abertos a inovações e são criativos.
- Processamento: essa dimensão refere-se à preferência do estudante sobre o processamento da informação. Subdivide-se em:
  - Ativo: a preferência é por experimentação ativa, discussões, trabalho em grupo. Gostam de situações que provocam experimentações e evitam as que exigem passividade do estudante.
  - Reflexivo: a preferência é por trabalho individual, introspecção, reflexão, teoria. Preferem situações que promovam tempo e espaço para abstração e levantamento de alternativas e hipóteses.



- **Organização:** essa dimensão refere-se à preferência de progressão do estudante dentro do curso. Demonstra a forma de organização do pensamento do estudante utilizada para a compreensão. Subdivide-se em:
  - **Sequencial:** a preferência é por uma progressão lógica e linear no conteúdo. O estudante que possui esse estilo apresenta pensamento convergente e analítico.
  - **Global:** a preferência é por uma visão geral do todo, aprendendo aleatoriamente. A informação é tratada de maneira holística. O estudante que possui esse estilo apresenta pensamento divergente e sintético.

Os estudantes apresentam tendências de preferências em cada uma das quatro dimensões (FELDER; SPURLIN, 2005). As dimensões definem as formas de receber, processar, perceber e organizar a informação (DORÇA, 2012). Uma importante característica do FSLSM é que suas dimensões não são estáticas, ou seja, um estudante pode tender de um EA para outro, dentro de uma mesma dimensão.

Com o objetivo de descobrir em quais dimensões o estudante se enquadra dentro do FSLSM, Solomon e Felder (1991) criaram o ILS (Index of Learning Style). O ILS é um questionário que possui 44 questões, sendo 11 questões para cada uma das quatro dimensões do FSLSM. Para cada uma das questões existem duas alternativas possíveis. De acordo com Silva (2012), a diferença na pontuação entre os estilos correspondentes a cada uma das quatro dimensões, indica a preferência do estudante de forma leve (1 e 3), moderada (5 e 7) e forte (9 e 11). Tomemos como exemplo a dimensão Organização, que pode ser Sequencial ou Global. Supondo que um estudante obtenha o resultado sequencial (8) e global (3), a diferença entre os estilos é 5, o que indica que o estudante possui uma preferência moderada pelo estilo sequencial (SILVA, 2012). A Figura 7 mostra a escala de classificação do ILS.

Figura 7 – Escala de Classificação do ILS

Visual	11	9	7	5	3	1	1	3	5	7	9	11	Verbal
Sensitivo	11	9	7	5	3	1	1	3	5	7	9	11	Intuitivo
Ativo	11	9	7	5	3	1	1	3	5	7	9	11	Reflexivo
Sequencial	11	9	7	5	3	1	1	3	5	7	9	11	Global

Fonte: Adaptado de Silva (2012).

O ILS é atualmente disponibilizado gratuitamente para estudantes e professores. O questionário pode ser acessado pelo endereço: <https://www.webtools.ncsu.edu/learningstyles/>.

### 2.3.6 Críticas aos Estilos de Aprendizagem

Embora exista na literatura um rico estudo sobre os EAs e uma variedade de modelos que buscam descrevê-los, algumas pesquisas recentes tem questionado a teoria. Essas pesquisas

levantam possíveis falhas na teoria e modelos de EA.

Uma das críticas está relacionada ao aspecto determinístico que os EAs supostamente apresentam. [Kirschner e Merriënboer \(2013\)](#) criticam a concepção de EA como uma característica fixa do indivíduo, onde o EA é estático e não pode variar ao longo do tempo. Crítica semelhante apresenta [Pashler \*et al.\* \(2008\)](#), ao constatarem que essa definição de um EA fixo pode levar o indivíduo a entender que não consegue aprender de determinadas formas, que não sejam aquelas de sua preferência.

Outra crítica aos EAs está relacionada às suas formas de detecção. [Rawson, Stahovich e Mayer \(2017\)](#) alega que a identificação de EA por meio de questionários muitas vezes não condiz com a realidade, visto que existe uma baixa correlação entre as respostas e o que é, de fato, verdade. [Veenman, Prins e Verheij \(2003\)](#) criticam o uso de questionários psicométricos para realizar a detecção dos EAs, visto que os estudantes não conseguem definir claramente a forma que melhor aprendem. [Graf, Lin \*et al.\* \(2007\)](#) abordam a imprecisão e grau de incerteza associados à este tipo de questionário para auto-avaliação de EA.

Apesar das críticas, pesquisas recentes tem demonstrado que a utilização de EAs nos Sistemas de Aprendizagem é uma tendência. Trabalhos como [Dorça \(2012\)](#), [Sena \*et al.\* \(2016\)](#), [Rodrigues \*et al.\* \(2016\)](#), [Falci \*et al.\* \(2017\)](#), [Salazar \*et al.\* \(2017\)](#), [Ribeiro \*et al.\* \(2017\)](#) e [Silva \*et al.\* \(2018\)](#) apresentam abordagens para detecção de EAs de forma automática, baseadas em técnicas de Inteligência Artificial e Aprendizagem de Máquina. As abordagens para detecção de EA de forma automática afastam uma das principais críticas à teoria, já que dispensam o uso de questionários para auto-avaliação dos estudantes.

Todos esses trabalhos utilizam ainda o FSLSM como modelo para descrição de EA. O FSLSM é um modelo dinâmico e probabilístico, onde os estudantes possuem tendências de preferências em cada dimensão ([DORÇA, 2012](#)). Sendo assim, o estudante possui uma probabilidade de pertencer a uma determinada dimensão de EA, mas possui também probabilidades menores de pertencer à outros estilos ([DORÇA, 2012](#)). O uso do FSLSM como modelo afasta então outra crítica à teoria, de que os EAs são tratados de forma determinística.

Ressalta-se, ainda, que as críticas aos EAs apresentadas neste trabalho, retiradas de [Kirschner e Merriënboer \(2013\)](#), [Pashler \*et al.\* \(2008\)](#), [Rawson, Stahovich e Mayer \(2017\)](#) e [Veenman, Prins e Verheij \(2003\)](#), fazem mais sentido quando aplicadas ao ensino presencial, já que no ensino na modalidade EaD existe o uso de ferramentas computacionais, que facilitam a detecção automática dos EAs e a classificação de acordo com um modelo como o FSLSM.

Por fim, a proposta apresentada neste trabalho utiliza o FSLSM como modelo e propõe uma abordagem automática para detecção de EA. Sendo assim, algumas críticas aos EAs foram consideradas e contornadas, o que demonstra, mais uma vez, a relevância científica da proposta.

## 2.4 Educação à Distância e as Tecnologias da Informação e Comunicação

A Educação à Distância (EaD) pode ser definida como a “modalidade educacional na qual a mediação didático-pedagógica nos processos de ensino-aprendizagem ocorre com a utilização de meios e tecnologias de informação e comunicação, com estudantes e professores desenvolvendo atividades educativas em lugares ou tempos diversos” (BRASIL, 2005).

A EaD é um processo educacional onde existe a separação física entre professor e aluno, mediado por tecnologias da informação e comunicação (PINHEIRO, 2002). Para Moore e Kearsley (2011), a EaD possui elementos interativos que englobam os processos de ensino, aprendizagem, comunicação e controle.

A EaD busca abrir novas oportunidades para a população em geral, reduzindo as desigualdades sociais e direcionando para os estudantes alguns dos controles que tradicionalmente pertenciam aos professores (OTERO *et al.*, 2008). Sendo assim, um aspecto importante da EaD é que ela se caracteriza pela autoaprendizagem do aluno. O principal fator que diferencia a EaD das outras modalidades de educação é a atenção centralizada no estudante e na sua autonomia no processo de aprendizagem (SABA, 2003).

NUNES (1992) destaca as possibilidades do uso da EaD, que incluem:

- Democratização do saber: a EaD amplia e democratiza o acesso à educação para a população em geral.
- Educação continuada: permite a oferta de cursos livres destinados à integração da população, visando a formação cidadã.
- Capacitação profissional e de professores: a EaD é uma alternativa viável para o desenvolvimento de programas de capacitação para docentes ou até mesmo o treinamento para funcionários de empresas.

A ideia de ofertar educação para pessoas que não tem condições de frequentar uma instituição de ensino presencial sempre foi muito discutida. O início da história da EaD retoma ao período entre as décadas de 1830 e 1840, quando surgiram na Europa as primeiras escolas por correspondência (ALVES, 2001).

Os registros sobre o surgimento da EaD no Brasil são incertos e imprecisos. Em 1891, foi registrado na seção de classificados do Jornal do Brasil um anúncio oferecendo curso profissionalizante em datilografia por correspondência (ALVES, 2001). No entanto, o marco histórico se deu com a implantação das Escolas Internacionais, representando organizações dos Estados Unidos da América, em 1904 (ALVES, 2001).

Várias foram as instituições responsáveis pela difusão da EaD no Brasil. Pode-se destacar: Rádio Sociedade do Rio de Janeiro, em 1923; Instituto Rádio Técnico Monitor, em 1939; Instituto Universal Brasileiro, em 1941; Igreja Adventista, em 1943; SENAC com o programa Universidade do Ar, no final da década de 1940; Diocese de Natal, em 1959; Ocidental

School, em 1962; Instituto Brasileiro de Administração Municipal, em 1967; Fundação Padre Landell de Moura, em 1967; entre outras ([ALVES, 2001](#)).

A história da EaD se divide em quatro fases ou gerações ([SHERRON; BOETTCHER, 1997](#)):

- 1ª geração (1850 - 1960): a EaD era praticada quase que unicamente por correspondência em papel.
- 2ª geração (1960 - 1985): a EaD era praticada com intermédio de várias tecnologias, como TV, fitas de vídeo, fax e papel.
- 3ª geração (1985 - 1995): a EaD passa a ser praticada com o auxílio de computadores, correio eletrônico, chat, entre outros.
- 4ª geração (1995 - atualidade): a EaD passa a utilizar a internet de alta velocidade. É considerado um marco, já que a utilização dos recursos tecnológicos permite uma maior interação entre professores, tutores e estudantes.

Com a criação da World Wide Web por Tim Bernes-Lee na década de 1990, a internet começou a se popularizar. A popularização dessa tecnologia é um marco para a EaD, já que a internet facilita o acesso aos cursos. Surge então o conceito de e-learning, que pode ser entendido como a utilização dos computadores e da internet como meio para proporcionar a EaD ([ROSENBERG, 2001](#)).

O e-learning apresenta diversos benefícios, tais como: a informação está disponível em escala global e pode ser atualizada a qualquer momento; a aprendizagem pode acontecer independente de hora e local; autonomia na aprendizagem; recursos multimídia podem facilitar e motivar mais a aprendizagem; com a utilização de fórum, chats e conferências, a aprendizagem colaborativa é facilitada; avaliações podem ser realizadas de forma autônoma; oferece novas abordagens para a aprendizagem; é um meio de economia para as instituições educacionais ([ANARAKI, 2004](#); [JISC, 2004](#)).

Nesse sentido, para a utilização da internet como um meio que permite facilitar e proporcionar a EaD e o e-learning, surgiram os Ambientes Virtuais de Aprendizagem.

#### 2.4.1 Ambiente Virtual de Aprendizagem

Um Ambiente Virtual de Aprendizagem (AVA) é o lugar onde ocorrem interações online entre os estudantes e professores ([JISC, 2004](#)). São sistemas de ensino-aprendizagem que proporcionam aos professores e estudantes montar e participar das aulas interagindo entre si, mesmo com a distância física ([VAZ; ZANELLA; ANDRADE, 2010](#)).

Os AVAs se caracterizam por integrar funções distintas que auxiliam professores, estudantes e tutores, como as ferramentas de comunicação (chat, e-mail, fóruns, etc); ferramentas de avaliação (envio de tarefas, provas, etc); matérias para o ensino (slides de apresentação,

conteúdo multimídia, leituras diversas, etc); ferramentas para monitoramento do estudante (contém estatísticas e dados diversos do uso do AVA pelo estudante) (OTERO *et al.*, 2008).

O processo educacional nos AVAs deve ser análogo àquele praticado em sala de aula (AMARAL; BORBA; MALHEIROS, 2007). Sendo assim, os estudantes devem ter as mesmas oportunidades do ensino presencial, bem como os professores devem ter recursos que se aproximam da realidade do ensino presencial (SENA *et al.*, 2016). Os AVAs devem, ainda, ser capazes de propiciar ao estudante uma aprendizagem de forma autônoma, além de estimular a criatividade, pesquisa e troca de experiências (TAJRA, 2011).

Ao longo dos anos, diversos AVAs contendo diferentes funcionalidades foram desenvolvidos pela comunidade, sendo alguns livres, outros pagos. Em seu trabalho, Gabardo, Quevedo e Ulbricht (2010) fizeram um levantamento das principais plataformas de Ambientes Virtuais de Aprendizagem existentes. Os autores fizeram um levantamento das oito principais plataformas que são as mais citadas e mais utilizadas pelas Instituições de Ensino Superior do Brasil. As plataformas mais utilizadas são (GABARDO; QUEVEDO; ULBRICHT, 2010):

- TelEduc: plataforma que pode ser distribuída ou modificada nos termos da GNU. Possui grupos de discussão, correio eletrônico, mural, portfólio, diário de bordo, bate-papo, enquetes, fórum de discussão. Apresenta alta usabilidade, mas não apresenta acessibilidade a deficientes auditivos e visuais.
- Edu web/Aulanet: plataforma disponibilizada gratuitamente. Propõe atividades colaborativas. Apresenta usabilidade média e não apresenta acessibilidade a deficientes auditivos e visuais.
- Amadeus: plataforma que pode ser distribuída ou modificada nos termos da GNU. Como princípio pedagógico, é orientado por teorias construtivistas ou sócio-interacionistas do desenvolvimento humano. Possui fórum, wiki, jogos multi-usuários (resolução colaborativa de problemas), chats, discussão síncrona, micromundos (ambientes síncronos), vídeos e recursos da web 2.0. Apresenta usabilidade média e não apresenta acessibilidade a deficientes auditivos e visuais.
- Eureka: plataforma desenvolvida para a comunidade acadêmica da PUC-PR. Propõe atividades colaborativas. Possui correio eletrônico, listas de discussão, fórum de discussão, além de oferecer áudio juntamente com texto. Apresenta usabilidade alta e acessibilidade parcial para deficientes visuais, embora não apresente acessibilidade a deficientes auditivos.
- e-Proinfo: plataforma disponibilizada para entidades e instituições conveniadas. Como princípio pedagógico, apresenta uma proposta colaborativa. Possui tira-dúvidas, agenda, diário, biblioteca, avisos, correio eletrônico, chat, fórum de discussão, banco de projetos e estatísticas de atividades dos alunos. Apresenta usabilidade baixa e não apresenta acessibilidade a deficientes auditivos e visuais.

- Moodle: plataforma que pode ser distribuída ou modificada nos termos da GNU. Como princípio pedagógico, apresenta uma proposta colaborativa. Possui fórum de discussão, gestão de conteúdos, blogs, wikis, vídeo-conferência, certificados digitais. Apresenta usabilidade alta e acessibilidade parcial para deficientes visuais.
- WebCT: plataforma proprietária provedor de e-learning para instituições de ensino. Oferece ferramentas educacionais que auxiliam o aprendizado, a comunicação e a colaboração. Possui chat, sistema de conferência e correio eletrônico. Apresenta usabilidade média e não apresenta acessibilidade a deficientes auditivos e visuais.
- LearningSpace: plataforma que pode ser distribuída ou modificada nos termos da GNU. Como princípio pedagógico, apresenta uma proposta colaborativa. Possui fórum de discussão, chat, avisos, vídeos, recursos web 2.0, além de utilizar redes sociais da web como ferramenta de interação. Apresenta usabilidade alta e menciona estar dentro das diretrizes de acessibilidade da W3C.

Os AVAs são a implementação dos sistemas conhecidos na literatura como Sistemas de Gestão de Aprendizagem (LMS - Learning Management System).

#### 2.4.2 Sistemas Hipermissão Adaptativa

Os LMS/AVA são sistemas especializados com tecnologias para o ensino e aprendizagem baseados na Internet e na Web, que visam fornecer educação e treinamento seguindo o paradigma da educação a distância ([AVGERIOU et al., 2003](#)).

Apesar dos LMS fornecerem grande apoio aos professores e alunos, esses sistemas não consideram as diferenças individuais dos estudantes e o mesmo conteúdo é apresentado para todos os usuários. Os LMS auxiliam na organização e controle das atividades programadas em um curso, mas não auxiliam o professor na preparação ou na escolha do conteúdo mais adequado a ser apresentado ao aluno ([PUGA, 2008](#)). Diante desse cenário, a adaptatividade desses sistemas a diferentes estudantes tem sido frequentemente discutida. Sendo assim, há alguns anos a área de Hipermissão Adaptativa (HA) vem ganhando destaque nas pesquisas da área de computação.

A Hipermissão Adaptativa é a área que estuda o desenvolvimento de sistemas que sejam capazes de prover adaptação de conteúdos e recursos hipermissão, sejam estes vindos de qualquer fonte (internet, banco de dados, serviços) e apresentados em diversos formatos (texto, áudio, vídeo) ([PALAZZO, 2002](#)).

A adaptação nos sistemas hipermissão se propõe a resolver quatro problemas principais ([OLIVEIRA; FERNANDES, 2002](#)):

- Quebra de fluxo conceitual: quando a estrutura apresenta muitos links, nem sempre é possível garantir que o usuário tenha passado por todos os nós que possuam uma relação de pré-requisito com o atual, o que dificulta o entendimento dos conceitos apresentados;

- Desorientação: em estruturas complexas de links, o usuário pode apresentar dificuldade para saber como chegou a um determinado nó, como voltar ou como chegar onde deseja;
- Quebra de fluxo narrativo: a passagem de um nó para outro pode não apresentar um fluxo suave, como esperam os usuários;
- Sobrecarga cognitiva: está relacionada à sobrecarga de informação apresentada ao usuário, seja ela em termos de conteúdos ou de links.

A ideia central dos Sistemas Hipermídia Adaptativos (SHA) é fornecer ao usuário um ambiente hipermídia preparado dinamicamente e adequado às suas necessidades, preferências e/ou características individuais. [Matos \(2013\)](#) aborda como principal objetivo dos SHAs a elaboração de modelos que representem adequadamente e dinamicamente o ambiente, considerando-se principalmente as características individuais de cada usuário. Para isso, o sistema deve ser concebido a partir de um Modelo de Usuário capaz de armazenar as características necessárias à formatação do ambiente ([PUGA, 2008](#)).

O Modelo de Usuário (MU), ou Modelo do Estudante (ME), é uma base de dados destinada a armazenar as características dos usuários que são utilizadas para que o sistema possa realizar a adaptação ([PUGA, 2008](#)). De acordo com [Wu, Houben e Bra \(2000\)](#), o modelo do usuário é o componente do SHA que representa as características de um determinado usuário que serão constantemente atualizadas.

As possibilidades de adaptação em Hipermídia Adaptativa são denominados Espaços de Adaptação ([BRUSILOVSKY, 2001b](#); [BRUSILOVSKY; MILLÁN, 2007](#)) e [Koch \(2001\)](#) os classifica em três grandes espaços:

- Conteúdo Adaptativo, que consiste na adaptação de um nó acessado por um usuário aos conhecimentos e objetivos definidos em seu Modelo de Usuário ([PALAZZO, 2002](#));
- Apresentação Adaptativa, que permite a adequação da configuração e/ou arranjo visual dos elementos da interface às preferências e/ou necessidades do usuário. A Apresentação Adaptativa está diretamente relacionada ao conteúdo adaptativo e, dessa forma, o layout adaptativo é implementado por meio de técnicas de Conteúdo Adaptativo ([KOCH, 2001](#));
- Navegação Adaptativa, que consiste em métodos que dão suporte à orientação do usuário, gerando visualizações personalizadas e alterando a estrutura ou a apresentação da navegação ([KOCH, 2001](#)).

[Koch \(2001\)](#) diferencia em seu trabalho os conceitos de sistemas adaptáveis e sistemas adaptativos. Um sistema adaptável permite ao usuário fazer modificações na sua estrutura, com o objetivo de customizá-lo de acordo com suas preferências ([KOCH, 2001](#)). A modificação do sistema é realizada de acordo com o critério do usuário.

Já os sistemas adaptativos realizam a adaptação aos usuários de forma automática, monitorando as ações do usuário no sistema e armazenando no Modelo do Usuário ([KOCH,](#)



2001). O comportamento do usuário no sistema é capturado de forma dinâmica através da interação do mesmo com o sistema ou por meio de questionários (KOCH, 2001). Sendo assim, a modificação do sistema é realizada automaticamente, sem a intervenção direta do usuário.

### 2.4.3 Sistemas Tutores Inteligentes

A história dos Sistemas Tutores Inteligentes (STIs) tem origens na área da Inteligência Artificial e da Educação, no final da década de 1950. A utilização do computador como uma máquina que poderia auxiliar no processo de aprendizagem teve seus primeiros esforços na década de 1960. Inicialmente eles foram pensados como ferramentas que poderiam oferecer suporte aos professores (VICARI; GIRAFFA, 2003). Nessa época, surgiram os conhecidos sistemas CAIs (Computer-Aided Instruction - Instrução Assistida por Computador).

Os sistemas CAIs eram sistemas baseados no Behaviorismo e a instrução era realizada pela apresentação linear e gradativa de diversos módulos de aprendizagem (VICARI; GIRAFFA, 2003). Sendo assim, esses primeiros programas dedicados ao ensino ficaram conhecidos como sistemas lineares, onde o conteúdo era apresentado de forma linear. O aluno seguia uma sequência de passos e isso o levaria ao aprendizado do conteúdo. No entanto, em nenhum momento o raciocínio do aluno era estimulado.

Os CAIs foram fortemente influenciados pelas teorias Behavioristas, que se preocupam com o comportamento observável e mensurável do indivíduo (FRAGELLI, 2011). O Behaviorismo é baseado na ideia de determinar a relação entre estímulos e respostas (FRAGELLI, 2011). Dessa forma, nos CAIs a aprendizagem era modelada a partir de estímulos planejados previamente (VICARI; GIRAFFA, 2003).

Como os sistemas CAIs não consideravam as diferenças entre os usuários e não se adaptavam aos perfis dos diferentes estudantes, na década de 1980 surgiram os sistemas ICAI (Intelligent Computer-Aided Instruction - Instrução Assistida por Computador Inteligente). Os ICAIs utilizam técnicas de inteligência artificial aliadas à Psicologia Cognitiva para orientar o processo de ensino-aprendizagem. O termo ICAI historicamente foi utilizado nas pesquisas da área de softwares educacionais (NWANA, 1990). No entanto, os ICAIs e os Sistemas Tutores Inteligentes (STIs) sempre foram considerados sinônimos, embora atualmente isso não seja consenso na área da Inteligência Artificial/Educação.

Os Sistemas Tutores Inteligentes são ambientes de aprendizagem assistidos por computador que são altamente adaptáveis e interativos (GRAESSER; CONLEY; OLNEY, 2012). Eles são modelos que utilizam as ciências da aprendizagem, ciências cognitivas, matemática e inteligência artificial (GRAESSER; CONLEY; OLNEY, 2012). Os STIs utilizam técnicas de inteligência artificial com o objetivo de proporcionar um ambiente de aprendizagem que considere os estilos cognitivos dos alunos (GIRAFFA, 1999). Assim, os STIs devem ser capazes de fornecer tutores inteligentes que saibam o que ensinar, quem ensinar e como ensinar (NWANA, 1990).

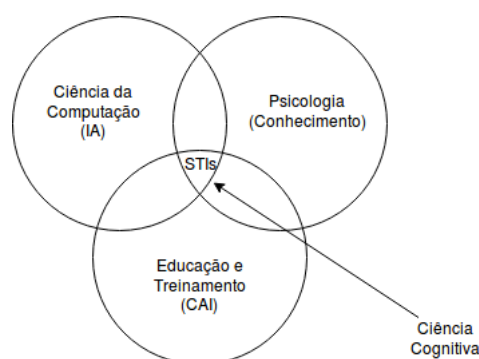
Algumas características importantes dos STIs são (LOINAZ, 2001):



- O conhecimento do domínio está restrito e bem articulado;
- Possuem conhecimento do estudante que lhe permite dirigir e adaptar o ensino;
- A sequência do ensino não está pré-determinada pelo programador;
- Realizam processos de diagnóstico mais detalhados e adaptados ao estudante;
- A comunicação entre tutor e aluno melhora, existindo a possibilidade do aluno fazer perguntas ao tutor.

Nwana (1990) define os STIs como a união de três diferentes disciplinas: Inteligência Artificial, Psicologia Cognitiva e Educação. Essa união resulta no domínio dos Sistemas Tutores Inteligentes, conforme Figura 8.

Figura 8 – Sistemas Tutores Inteligentes - União de três diferentes disciplinas



Fonte: Adaptado de Nwana (1990).

Embora os STIs prometam ser eficazes na melhoria da aprendizagem do estudante, historicamente eles tem se mostrado difíceis de construir (MURRAY, 2003). Um dos fatores que contribui para a dificuldade na construção dos STIs é sua arquitetura, que geralmente tende a ser complexa (WAALKENS; ALEVEN; TAATGEN, 2013).

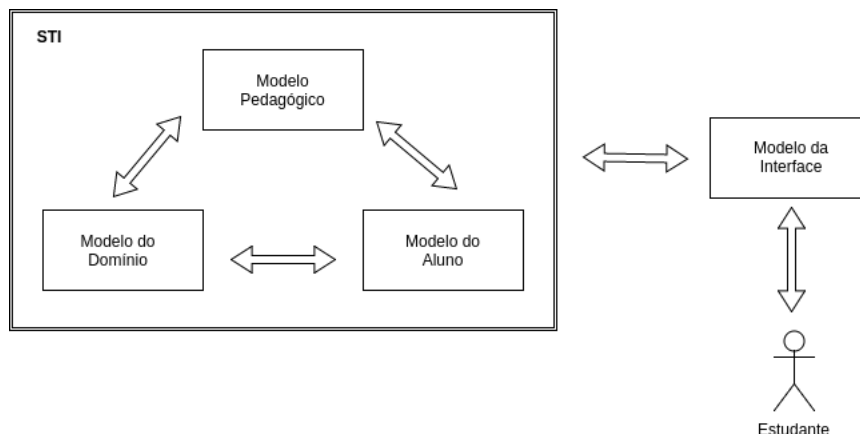
A arquitetura de um STI tradicional foi proposta na década de 1970 por Carbonell (1970) e é baseada em módulos que se relacionam entre si (NWANA, 1990). A arquitetura é composta por quatro modelos (VICARI; GIRAFFA, 2003):

- Modelo do Aluno: é o módulo do STI que possui o conhecimento, habilidades cognitivas e estilos cognitivos do estudante em determinado momento. O modelo do aluno armazena todo o conhecimento e comportamento do estudante.
- Modelo Pedagógico: é o módulo do STI que contém as estratégias pedagógicas, as táticas de ensino. Representa o conhecimento pedagógico do sistema. Também é conhecido como Modelo do Tutor.

- **Modelo do Domínio:** é o módulo do STI responsável por manipular o conhecimento que será utilizado no processo de ensino, abrangendo o material instrucional, geração de exemplos, simulações e diagnósticos.
- **Modelo da Interface:** é o módulo do STI que corresponde à interface entre o estudante e o sistema. O modelo da interface apresenta o material instrucional e monitora o progresso do aluno no curso.

Sendo assim, os STIs possuem um Modelo do Aluno, que caracteriza e individualiza o estudante para que este possa obter um ensino especializado, de acordo com suas características e preferências. As estratégias de como ensinar determinado conteúdo estão no Modelo Pedagógico (ou Modelo do Tutor) e o conteúdo da matéria a ser ensinada está no Modelo do Domínio. Todos esses módulos se intercomunicam e a interface entre o aluno e esses módulos é realizada por meio do Modelo da Interface. A arquitetura tradicional de um STI está representada graficamente na Figura 9.

Figura 9 – Arquitetura Tradicional dos Sistemas Tutores Inteligentes



Fonte: Adaptado de [Nwana \(1990\)](#).

Existem diversas outras variações de arquiteturas de STIs, todas baseadas na arquitetura tradicional representada pela figura 9. No entanto, neste trabalho não será realizada nenhuma revisão ou maior detalhamento das diferentes arquiteturas propostas para STIs, pois entende-se que este não é o objetivo maior da pesquisa. Foi utilizado, para fins do desenvolvimento da pesquisa, a arquitetura tradicional dos STIs. Mais especificamente, esta pesquisa busca focar na construção e atualização automática das características do aluno, presentes no Modelo do Aluno.

#### 2.4.4 Sistemas Educacionais Inteligentes e Adaptativos Baseados na Web

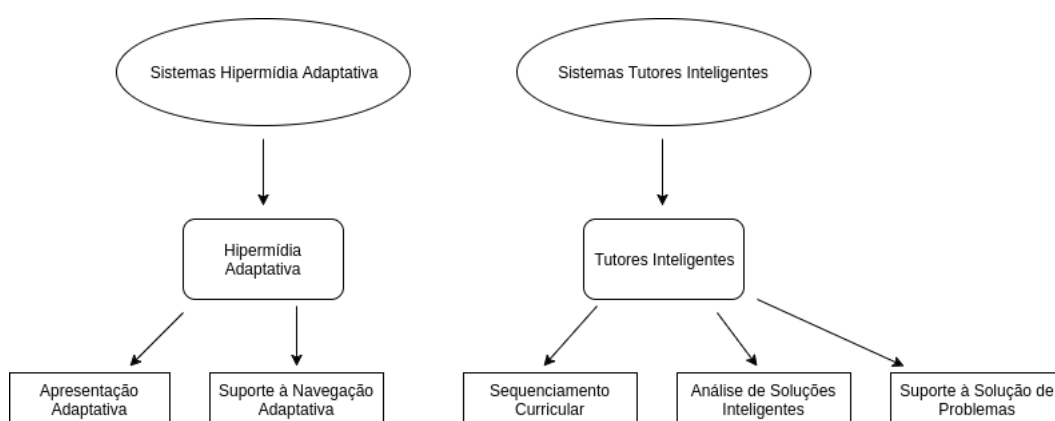
Existe uma diferença na concepção e nos objetivos dos STIs e dos SHAs. Enquanto os STIs são os sistemas responsáveis por selecionar o material de acordo com as características do estudante, os SHAs trabalham os conceitos relativos à construção de hiperdocumentos para apresentação e navegação que se adaptem ao usuário ([FRAGELLI, 2011](#)).

Para Brusilovsky e Peylo (2003), os SHAs buscam ser diferentes para os diferentes alunos, levando em consideração as informações existentes no modelo do usuário. Já os STIs aplicam técnicas de Inteligência Artificial para oferecer um suporte maior e melhor para os usuários dos sistemas educacionais baseados na web (BRUSILOVSKY; PEYLO, 2003).

A criação de um projeto de sistema educacional que inclua os STIs e os SHAs como sistemas complementares tem sido objeto de pesquisas recentes (FRAGELLI, 2011). A união desses dois sistemas resulta nos Sistemas Educacionais Inteligentes e Adaptativos baseados na Web (AIWBES - Adaptive and Intelligent Web-based Educational Systems).

Os AIWBES possuem um modelo de metas, preferências e conhecimentos de cada estudante e é capaz de se adaptar às necessidades dos alunos de acordo com esse modelo (BRUSILOVSKY; PEYLO, 2003). São capazes também de incorporar algumas atividades tradicionalmente executadas por um professor, como o treinamento de estudantes ou diagnóstico de erros dos alunos (BRUSILOVSKY; PEYLO, 2003). As origens dos AIWBES e suas principais tecnologias, podem ser visualizadas na Figura 10.

Figura 10 – AIWBES - Origens e Principais Tecnologias



Fonte: Adaptado de Brusilovsky e Peylo (2003).

Brusilovsky e Peylo (2003) chamam a atenção para a importância e as possibilidades dos AIWBES como um novo campo da Inteligência Artificial aplicada à educação. Apenas o fato de ser um sistema baseado na web já o deixa mais interessante, devido a sua simplicidade de acesso para os usuários e os pesquisadores.

## 2.5 Detecção de Estilos de Aprendizagem

Os EAs correspondem às preferências individuais dos estudantes no que diz respeito à aprendizagem e considerá-los no processo de ensino-aprendizagem tem papel fundamental na qualidade e nos resultados obtidos. Portanto, a criação do modelo do estudante com as características individuais de cada aluno, a partir da detecção dos EAs, se faz necessária dentro do contexto dos AIWBES.

Existem duas maneiras diferentes de realizar a detecção dos EAs ([BRUSILOVSKY, 1996](#)):

- Abordagem colaborativa: os estudantes fornecem suas preferências explicitamente, geralmente por meio de questionários;
- Abordagem automática: de acordo com o comportamento e as ações tomadas pelo estudante dentro do sistema, o ambiente consegue detectar e atualizar o estilo de aprendizagem do estudante automaticamente.

Com o decorrer do tempo, diversas abordagens para detecção e correção de estilos de aprendizagem foram desenvolvidas. Algumas delas são abordagens colaborativas que utilizam questionários psicométricos. Outras, abordagens computacionais que utilizam técnicas de Aprendizado de Máquina, Inteligência Computacional e Inteligência Artificial para detectar o EA do estudante automaticamente. Nas próximas subseções, será realizado um levantamento das principais técnicas para detecção dos EAs.

### 2.5.1 Questionários

Com o objetivo de determinar os estilos de aprendizagem de um estudante, em 1991 Richard Felder e Barbara Soloman criaram um questionário psicométrico denominado Index of Learning Style (ILS) ([FELDER; BRENT, 2005](#)). O ILS é composto por quarenta e quatro perguntas, sendo onze perguntas para cada uma das quatro dimensões do FSLSM. A partir das respostas do questionário é possível determinar o EA do estudante.

O ILS está disponível gratuitamente para uso dos estudantes ou dos professores que desejam realizar um levantamento dos EAs de seus alunos ([FELDER; BRENT, 2005](#)). O questionário já foi testado e validado diversas vezes.

No entanto, existem algumas críticas em relação ao uso dessa abordagem colaborativa para determinação dos estilos de aprendizagem. [Graf, Lin et al. \(2007\)](#) abordam a imprecisão e o grau de incerteza associados à questionários psicométricos para auto-avaliação de EA. Isso ocorre por fatores como a dificuldade de auto-concepções pelo estudante ([FELDER; SPURLIN, 2005](#)), e também por exigir tempo e paciência no preenchimento. Ainda, [Dorça \(2012\)](#) destaca o fato do modelo não considerar o aspecto dinâmico dos EA, sendo que um estudante pode tender de um estilo para outro ao longo do tempo.

Existem ainda outros questionários que foram propostos para se adequar a outros modelos de descrição de estilos de aprendizagem, como o Kolbs Learning Style Inventory (LSI), baseado no modelo proposto por ([KOLB; BOYATZIS; MAINEMELIS, 1984](#)). Porém, esses questionários apresentam os mesmos problemas do ILS.

### 2.5.2 Redes Bayesianas

As Redes Bayesianas são uma representação compacta e expressiva de relações incertas entre parâmetros de um domínio (GARCIA *et al.*, 2007). São estruturas capazes de modelar situações que apresentam algum grau de incerteza e não são determinísticas.

Dessa forma, as Redes Bayesianas se adequam muito bem para a detecção de estilos de aprendizagem, se considerarmos que esse é um problema não determinístico e que apresenta certo grau de incerteza. Com a técnica de Redes Bayesianas é possível criar uma rede entre os padrões de comportamento do estudante e as dimensões do modelo de EA utilizado (AL-AZAWEI; BADII, 2014).

Vários autores já desenvolveram pesquisas relacionadas à detecção dos EA utilizando a abordagem de Redes Bayesianas. Podemos citar os trabalhos de (GARCIA *et al.*, 2005), (GARCIA *et al.*, 2007), (GARCIA; SCHIAFFINO; AMANDI, 2008), (BOTSIOS; GEORGIU; SAFOURIS, 2008) e (Essaid El Bachari; El Adnani, 2011).

O trabalho de Garcia *et al.* (2007) foi um dos primeiros a relacionar Redes Bayesianas e o FSLSM. Garcia *et al.* (2007) utiliza o Teorema de Bayes para inferir as características do estudante após observar seu comportamento durante o processo de aprendizagem.

Para avaliar sua abordagem, Garcia *et al.* (2007) utilizou 27 estudantes de um curso de Inteligência Artificial em um Ambiente Virtual de Aprendizagem. Os resultados foram comparados com resultados obtidos pelo ILS, proposto por Felder. Foi verificado um grande índice de acerto entre as probabilidades inferidas pela Rede Bayesiana e o resultado obtido pelo questionário ILS.

Dessa forma, Garcia *et al.* (2007) conseguiu comprovar com sua pesquisa a eficiência e viabilidade do uso de Redes Bayesianas para detecção e correção automática dos estilos de aprendizagem utilizando o FSLSM em ambientes virtuais de aprendizagem reais.

### 2.5.3 Redes Neurais Artificiais

As Redes Neurais Artificiais são modelos computacionais baseados na estrutura dos neurônios do cérebro humano e tem como objetivo reproduzir a maneira como o sistema nervoso humano trabalha (VILLAYERDE; GODOY; AMANDI, 2006). O principal elemento da rede é o neurônio artificial, que está conectado a outros neurônios, e estes formam uma rede de neurônios. Por meio desta rede, os sinais são transmitidos e geram as sinapses, responsáveis pelo aprendizado da rede (VILLAYERDE; GODOY; AMANDI, 2006).

Alguns autores já desenvolveram pesquisas relacionadas à detecção e correção de estilos de aprendizagem utilizando a abordagem de Redes Neurais Artificiais. Podemos citar (VILLAYERDE; GODOY; AMANDI, 2006), (CABADA; ESTRADA; GARCIA, 2011), (MANGHIRMALANI; PANTHAKY; JAIN, 2011) e (LO; CHAN; YEH, 2012).

Lo, Chan e Yeh (2012) propõem um sistema de aprendizagem baseado na web que possui dois módulos: o modelo do estudante e o modelo adaptativo. O modelo do estudante, após

coletar informações sobre o comportamento do mesmo durante as sessões de aprendizagem, faz uso de uma rede neural do tipo multicamada feed-forward para classificar o comportamento do aluno (LO; CHAN; YEH, 2012).

A validação da abordagem foi feita com estudantes reais. Os resultados mostraram que o treinamento da rede neural foi apropriado e o ambiente conseguiu inferir o estilo cognitivo do estudante com um alto grau de precisão (LO; CHAN; YEH, 2012). Os autores consideraram, por fim, que o uso da rede neural multicamada possui potencial para poder ser utilizado em um ambiente virtual de aprendizagem.

Embora a utilização de redes neurais para detecção dos estilos de aprendizagem dos estudantes tenha se mostrado promissora, Al-Azawei e Badii (2014) ressaltam que essa abordagem deve ser melhor avaliada, pois apresenta um elevado custo computacional e grande complexidade.

#### 2.5.4 Árvore de Decisão

De acordo com Russell e Norvig (1995), uma Árvore de Decisão é uma estrutura computacional utilizada para aprendizado de máquina e tomada de decisão. As árvores utilizam uma situação problema (conjunto de atributos) como entrada e geram uma hipótese como saída (RUSSELL; NORVIG, 1995). Esse método é bastante utilizado por apresentar estrutura simples, porém poderosa.

O problema de detecção e correção automática dos estilos de aprendizagem já foi modelado por alguns autores utilizando a estrutura de Árvore de Decisão. Cha *et al.* (2006) e Özpölat e Akar (2009) são exemplos de pesquisadores que utilizaram essa abordagem para identificação dos estilos de aprendizagem.

Özpölat e Akar (2009) utilizam uma estrutura de árvore combinada com o algoritmo NBTree e o classificador Binary Relevance para modelar os estilos de aprendizagem, baseados no FSLSM. Nessa abordagem, o estudante interage com o ambiente virtual de aprendizagem, que oferece objetos de aprendizagem genéricos ao estudante. De acordo com as opções do estudante pelos objetos, as mesmas são agrupadas e organizadas na árvore de decisão (ÖZPOLAT; AKAR, 2009).

A partir da geração da árvore, utiliza-se o algoritmo NBTree para inferir o estilo de aprendizagem do estudante. Assim, os estudantes são classificados de acordo com seus interesses e, conforme o resultado da classificação, são identificados os estilos de aprendizagem (ÖZPOLAT; AKAR, 2009).

Já a abordagem proposta por Cha *et al.* (2006) utiliza Árvores de Decisão combinadas com Modelos Ocultos de Markov. Através da interação do estudante com o ambiente virtual de ensino, o sistema coleta suas preferências individuais e as armazena em uma estrutura de Árvore de Decisão. A detecção dos estilos de aprendizagem é realizada utilizando o Modelo Oculto de Markov, um método estatístico que utiliza a sequência de observações e as probabilidades para inferir os resultados.

### 2.5.5 Algoritmo Genético

Algoritmos Genéticos são heurísticas baseadas na Teoria da Evolução de Charles Darwin (YANNIBELLI; GODOY; AMANDI, 2006). Com base nessa técnica, uma população de soluções candidatas a um problema de otimização evolui para melhores soluções, através dos princípios naturais de herança, mutação, seleção natural e recombinação (YANNIBELLI; GODOY; AMANDI, 2006).

Algumas abordagens para identificação de estilos de aprendizagem utilizando Algoritmos Genéticos já foram propostas. Chang *et al.* (2009) propõem um método para classificar e identificar estilos de aprendizagem de estudantes. O autor utiliza o K-Nearest Neighbor como classificador, juntamente com um Algoritmo Genético.

Yannibelli, Godoy e Amandi (2006) utiliza um Algoritmo Genético que busca identificar as ações do aluno ao frequentar uma disciplina. Assim, as ações observadas são consideradas como as preferências do estudante e então são mapeadas para o FSLSM. No seu algoritmo, Yannibelli, Godoy e Amandi (2006) define a população inicial de cromossomos, de forma que cada cromossomo representa uma combinação de ações. Cada cromossomo dessa população é avaliado de acordo com as ações feitas pelo aluno. Uma nova população é obtida por meio de técnicas de seleção, crossover e mutação (YANNIBELLI; GODOY; AMANDI, 2006).

Yannibelli, Godoy e Amandi (2006) realizou testes com uma base de dez estudantes e seu algoritmo mostrou um alto índice de acerto na inferência dos EAs. A taxa de acerto na detecção foi de 80% para a dimensão Processamento, 100% para a dimensão Percepção e 100% para a dimensão Organização. Yannibelli, Godoy e Amandi (2006) não considerou no seu algoritmo a dimensão Entrada do FSLSM.

### 2.5.6 Aprendizagem por Reforço e Cadeias de Markov

A Aprendizagem por Reforço é uma técnica da Inteligência Artificial que utiliza recompensas para que o agente possa aprender (RUSSELL; NORVIG, 1995). Através da interação do agente com o ambiente, o mesmo consegue aprender, de acordo com as recompensas que lhe são oferecidas.

A Aprendizagem por Reforço é geralmente utilizada quando não se consegue obter exemplos de qual o comportamento correto que o agente deve ter em determinadas situações, ou quando o agente está em um ambiente desconhecido. Assim, logo após realizar alguma ação, o agente toma conhecimento do estado alcançado e consegue obter experiência sobre o ganho de suas ações em determinado estado (DORÇA, 2012).

Sendo assim, a Aprendizagem por Reforço é um método adequado para ser utilizado em situações onde não se possui uma base de conhecimento capaz de informar os objetivos e ações corretas, como é o caso da detecção automática e dinâmica de estilos de aprendizagem (DORÇA, 2012).

Dorça (2012) apresenta uma abordagem que utiliza Aprendizagem por Reforço, onde



o processo de atualização do Modelo do Estudante é feito a partir do desempenho dos estudantes. O desempenho do estudante, por sua vez, é aferido utilizando-se um Processo Estocástico para Simulação do Desempenho do Estudante - PESDE, metodologia criada pelo autor.

O Modelo do Estudante é modelado com uma cadeia de Markov para cada dimensão do FSLSM, e é formado por uma combinação de objetivos de aprendizagem, estilos de aprendizagem e nível cognitivo. A abordagem utiliza o algoritmo Q-learning para, de acordo com o resultado do desempenho do estudante calculado pelo PESDE, realizar a retroalimentação e atualização do modelo de estudante, representado pelas cadeias de Markov.

Para realizar os testes e validar sua abordagem, [Dorça \(2012\)](#) utilizou a metodologia de simulação computacional. Os resultados obtidos foram satisfatórios, pois foi detectado um alto grau de coesão entre o modelo do estudante probabilístico e o modelo do estudante real, com um baixo custo computacional.

#### 2.5.7 Mineração de Dados Educacionais

A Mineração de Dados tem como objetivo utilizar técnicas para descoberta de conhecimento em bases de dados. Recentemente, muito se tem discutido sobre a Mineração de Dados Educacionais, que consiste em aplicar métodos da Mineração de Dados para a descoberta de conhecimento em bases de dados de ambientes educacionais ([BAKER; ISOTANI; CARVALHO, 2011](#)).

[Senechal \(2013\)](#) afirma que essa abordagem utiliza informações da interação do aluno com o ambiente virtual, armazenadas nos arquivos de logs, para buscar padrões e inferir os estilos de aprendizagem dos estudantes.

De acordo com [Baker, Isotani e Carvalho \(2011\)](#), uma das principais linhas de pesquisa da Mineração de Dados Educacionais é o desenvolvimento de métodos eficazes para dar suporte ao aluno que utiliza ambientes virtuais de aprendizagem. Ainda segundo o autor, alguns Sistemas Tutores Inteligentes na Europa e EUA já utilizam técnicas de Mineração de Dados Educacionais para proporcionar uma aprendizagem mais personalizada e de melhor qualidade.

Existe ainda a possibilidade de utilizar os dados coletados como entrada para outros algoritmos da Inteligência Artificial que possam realizar a inferência dos estilos de aprendizagem ([AL-AZAWEI; BADII, 2014](#)). Assim, os dados podem servir de insumo para técnicas como as Redes Bayesianas, Redes Neurais Artificiais, entre outros.

Esse é o caso do trabalho de [Rajper et al. \(2016\)](#), que utiliza técnicas de mineração de dados e Redes Bayesianas para inferir os estilos de aprendizagem. A pesquisa foi realizada com 863 estudantes matriculados em cursos de Ciência da Computação. Para validação da pesquisa, os resultados foram comparados com resultados do questionário KLSI, utilizado para classificar os estudantes de acordo com o modelo do Kolb's Learning Style Model. Por fim, o autor avalia que os resultados obtidos podem melhorar no futuro com o aprimoramento da técnica ([RAJPER et al., 2016](#)).



### 2.5.8 Máquina de Vetores de Suporte

Uma Máquina de Vetores de Suporte (Support Vector Machine - SVM) é uma técnica da área da Inteligência Computacional, baseada na Teoria de Aprendizado Estatístico (GONG; WANG, 2011). Uma SVM é um classificador binário, pois possui como entrada um conjunto de dados e infere, para cada entrada, qual das duas classes a entrada faz parte.

Amir *et al.* (2016) propõe uma abordagem para detecção de estilos de aprendizagem através do método baseado em literatura e as SVM. Os autores analisaram dados de duzentos alunos através dos logs de arquivos de um sistema de gestão de aprendizagem. Utilizaram, então, o SVM para inferir os estilos de aprendizagem dos estudantes. Os resultados foram comparados com resultados obtidos utilizando o classificador Naive Bayes. Os resultados da SVM se mostraram superiores aos resultados utilizando Naive Bayes, o que comprova a viabilidade da proposta (AMIR *et al.*, 2016).

### 2.5.9 Lógica Fuzzy

A Lógica Fuzzy é baseada na teoria dos conjuntos fuzzy e se difere dos sistemas lógicos tradicionais devido a suas características e detalhes (GOMIDE; GUDWIN; TANSCHKEIT, 1995). É a lógica onde os modelos de raciocínio são aproximados, e não exatos (GOMIDE; GUDWIN; TANSCHKEIT, 1995). Na Lógica Fuzzy, o valor verdade de uma proposição pode ser um subconjunto fuzzy de qualquer conjunto parcialmente ordenado (GOMIDE; GUDWIN; TANSCHKEIT, 1995).

De acordo com Rodrigues *et al.* (2016), a Lógica Fuzzy é uma técnica que se adequa bem em situações onde não existe uma definição única de determinadas características, como é o caso da modelagem de EA.

Rodrigues *et al.* (2016) propõe uma abordagem baseada em Lógica Fuzzy para detecção dos EAs dos estudantes. Nesse modelo, o autor classifica as notas do estudante de acordo com alguns conjuntos difusos: Muito Ruim, Ruim, Média, Boa e Muito Boa. Cada nota pertence a um determinado conjunto difuso com um certo grau de pertinência que varia entre 0 e 1 (RODRIGUES *et al.*, 2016).

Sendo assim, o sistema seleciona, por meio de algumas regras de defuzzificação, uma Combinação de Estilo de Aprendizagem que contenha uma baixa média de notas ruins e alta média de notas boas (RODRIGUES *et al.*, 2016). Os resultados do algoritmo foram comparados com resultados obtidos pelo algoritmo descrito por (DORÇA, 2012). A abordagem proposta se mostrou superior devido à sua baixa variabilidade nos resultados e um melhor desempenho do algoritmo (RODRIGUES *et al.*, 2016).

### 2.5.10 Modelo Oculto de Markov

Um Modelo Oculto de Markov é uma variação das cadeias de Markov, pois além de apresentar as distribuições de probabilidades comuns às cadeias de Markov, ele possui também

uma distribuição baseada em observação e comportamento do ambiente em que está inserido (RABINER, 1989).

Um Modelo Oculto de Markov é um processo duplamente estocástico, onde um dos processos estocásticos é não visível e não observável, e o outro é um processo que produz uma sequência de observações (RABINER, 1989). Dessa forma, o primeiro processo estocástico, não visível, pode ser observado pelo segundo processo estocástico, que produz a sequência de observações.

Alguns autores já utilizaram a abordagem de Modelo Oculto de Markov para detectar os EA de estudantes. Pode-se destacar as propostas de (NGUYEN, 2013) e (SENA *et al.*, 2016).

A abordagem proposta por Nguyen (2013) utiliza um Modelo Oculto de Markov para cada dimensão do FSLSM. As subdimensões das dimensões formam os estados ocultos do modelo, enquanto as observações das ações do estudante no sistema compõe os estados observados do modelo.

A inferência dos EA, no caso da modelagem por meio dos Modelos Ocultos de Markov, está relacionada a resolver o problema de encontrar a melhor sequência de estados ocultos que influenciou na geração dos estados observados do modelo. Ou seja, qual sequência de transição de estados é mais provável que tenha conduzido a uma sequência de observações (NGUYEN, 2013). A melhor solução para esse problema, conforme Nguyen (2013), é utilizar o Algoritmo de Viterbi.

Sena *et al.* (2016) implementou a modelagem de EA utilizando os Modelos Ocultos de Markov e o Algoritmo de Viterbi para inferir os estilos. Os resultados foram satisfatórios, com uma taxa de acerto de estilo de aprendizagem probabilístico acima de 85% para cada dimensão do FSLSM.

### 3 ABORDAGEM PROPOSTA

O desenvolvimento da presente pesquisa se deu em três etapas. A primeira etapa consistiu na realização de um vasto estudo na literatura para levantamento de diferentes formas de modelagem do estudante em Sistemas Educacionais Inteligentes e Adaptativos Baseados na Web. A pesquisa abrangeu, ainda, os diferentes métodos para detecção automática dos EA propostos nos diversos trabalhos. Foi feito também um estudo sobre os conceitos matemáticos envolvidos na proposta, principalmente aqueles relacionados ao formalismo do Modelo Oculto de Markov e ao Algoritmo de Viterbi.

Na segunda parte da pesquisa, foi proposta uma forma de modelagem dos EAs baseado em Modelos Ocultos de Markov e FSLSM, utilizando o Algoritmo de Viterbi para inferir os EAs probabilísticos. Sendo assim, foi implementada a proposta de [Nguyen \(2013\)](#), utilizando a linguagem de programação Java.

Na terceira etapa, foi implantado um módulo para correção de estilos de aprendizagem, por meio de uma abordagem por reforço, proposta em [Dorça \(2012\)](#). Dessa forma, sempre que o estudante apresentar um rendimento inferior a um limite preestabelecido, será aplicado um reforço no seu modelo de estudante (ou seja, no Modelo Oculto de Markov). Esse reforço será aplicado porque um rendimento baixo pode indicar um problema de aprendizagem, que pode ter sido ocasionado pela não identificação correta do seu EA.

A validação da proposta foi realizada utilizando-se as interações dos alunos de um curso com um Sistema de Gestão de Aprendizagem. Para isso, foi utilizada a base de dados do trabalho de [Yannibelli, Godoy e Amandi \(2006\)](#). Simultaneamente às etapas descritas, foram realizadas as análises dos resultados.

As próximas seções apresentam os conceitos que embasam o que está sendo proposto, bem como a estrutura da abordagem apresentada.

#### 3.1 Modelos Ocultos de Markov

O formalismo do Modelo Oculto de Markov (Hidden Markov Model - HMM) foi descrito pela primeira vez no final dos anos 1960, por [Baum e Petrie \(1966\)](#) e [Baum, Eagon et al. \(1967\)](#). Inicialmente, os modelos eram aplicados para reconhecimento de palavras. Com o tempo, eles passaram a ser utilizados também em outras áreas, como no reconhecimento de voz ([LEE et al., 1990](#); [RABINER; WILPON; SOONG, 1989](#)), detecção de falhas em sistemas dinâmicos ([SMYTH, 1994](#)), verificação online de assinatura ([YANG; WIDJAJA; PRASAD, 1995](#)), entre outros.

Um HMM é uma variação das cadeias de Markov, pois além de apresentar as distribuições de probabilidades comuns às cadeias de Markov, ele possui também uma distribuição baseada em observação e comportamento do ambiente em que está inserido ([RABINER, 1989](#)).

Rabiner (1989) define um HMM como um processo duplamente estocástico, onde um dos processos estocásticos é não visível e não observável, e o outro é um processo que produz uma sequência de observações. Dessa forma, o primeiro processo estocástico, não visível, pode ser observado pelo segundo processo estocástico, que produz a sequência de observações.


De forma genérica, um HMM pode ser descrito pelo conjunto de parâmetros do modelo  $\lambda = (A, B, \pi)$ , onde  $\pi$  representa o vetor de probabilidades inicial da cadeia oculta de Markov, A representa a matriz de transição entre os estados e B representa a matriz de probabilidade de emissão de estados observáveis (SENA *et al.*, 2016).

O HMM apresenta alguns elementos fundamentais (RABINER, 1989):

- N, o conjunto de estados do modelo, representados por  $S = s_1, s_2, \dots, s_n$  em um espaço de tempo t em  $q_t$ ;
- M, conjunto de estados observáveis, denotados por  $V = v_1, v_2, \dots, v_m$ ;
- Distribuição de probabilidade da transição do estado,  $A = a_{ij}$ , sendo  $a_{ij} = P[q_{t+1} = S_j | q_t = s_i], 1 \leq i, j \leq N$ ;
- Distribuição de probabilidades de estados observáveis no estado j,  $B = b_j(k)$ , sendo  $b_j(k) = P[v_k \text{ em } t | q_t = S_j], 1 \leq j \leq N \text{ e } 1 \leq k \leq M$ ;
- Distribuição inicial de probabilidades  $\pi$ , sendo  $\pi_i = P[q_1 = S_i], 1 \leq i \leq N$ .

Um exemplo de modelagem utilizando HMM na área educacional está descrito em Nguyen (2013). O problema está relacionado a determinar o EA do estudante em determinada dimensão do FSLSM, de acordo com as observações sobre sua interação com o sistema de aprendizagem. Nessa situação, em relação à dimensão entrada, os estados ocultos são os EA possíveis: Visual ou Verbal. Os estados observáveis são as observações que se pode fazer a partir da interação do estudante com o sistema: leitura de textos, visualização de imagens ou vídeos. O HMM que representa essa situação pode ser visualizado na Figura 11.

Figura 11 – Modelo Oculto de Markov para a Dimensão Entrada do FSLSM



Fonte: Adaptado de Nguyen (2013).

As transições entre os estados são probabilidades, representadas por meio de uma matriz de transição de estados ocultos (Tabela 2) e uma matriz de emissão de estados observáveis (Tabela 3).

Tabela 2 – Matriz de transição de estados ocultos - HMM para determinação de EA na dimensão Entrada

	<b>Visual</b>	<b>Verbal</b>
<b>Visual</b>	0,7	0,3
<b>Verbal</b>	0,3	0,7

Fonte: Próprio autor.

Tabela 3 – Matriz de emissão de estados observáveis - HMM para determinação de EA na dimensão Entrada

	<b>Texto</b>	<b>Imagem</b>	<b>Vídeo</b>
<b>Verbal</b>	0,6	0,3	0,1
<b>Visual</b>	0,2	0,4	0,4

Fonte: Próprio autor.

Conforme (RABINER, 1989), existem três problemas fundamentais que envolvem a modelagem por meio de Modelos Ocultos de Markov. O primeiro problema está relacionado ao cálculo eficiente da probabilidade de uma sequência de estados observáveis. O segundo problema é encontrar a melhor sequência de estados ocultos que influenciou na geração dos estados observados do modelo. Já o terceiro e último problema consiste em definir uma metodologia de treinamento e aprendizado de máquina com objetivo de maximizar o cálculo das probabilidades na sequência de estados observáveis (SENA *et al.*, 2016). Abaixo, com mais detalhes, os três problemas canônicos e os algoritmos propostos para a resolução serão descritos.

### 3.1.1 Primeiro Problema - Verossimilhança

O primeiro problema (conhecido como problema da verossimilhança) que envolve a modelagem por meio de Modelos Ocultos de Markov está relacionado ao cálculo da probabilidade de uma sequência de estados observáveis. Sendo assim, dado um modelo  $\lambda = (A, B, \pi)$  e a sequência de estados observáveis  $V = (v_1, v_2, \dots, v_T)$ , como calcular a probabilidade de se gerar a sequência de observáveis a partir do modelo (ALAMINO, 2005).

Os métodos tradicionais para resolução do problema da verossimilhança apresentam um alto custo computacional, já que o número de multiplicações necessárias para o cálculo da soma seria na ordem de  $(2T - 1)n^T$  (ALAMINO, 2005). No entanto, existem dois algoritmos de complexidade polinomial que foram desenvolvidos para a resolução deste problema. São eles o Forward Procedure e o Backward Procedure.

O Forward Procedure é um algoritmo recursivo que é iniciado com uma variável forward  $f_1(i) = P(v_1 \dots v_t, q_t = S_i | \lambda)$ . O algoritmo é executado da seguinte forma (PETRUSHIN, 2000; SENA *et al.*, 2016; ALAMINO, 2005):

- Inicialização:  $f_1(i) = \pi_i e_i(v_1), 1 \leq i \leq N$ ;
- Recursão:  $f_{t+1}(j) = e_j(v_{t+1}) \sum_{i=1}^N f_t(i) a_{ij}, 1 \leq t \leq T-1, 1 \leq j \leq N$ ;
- Finalização:  $P(V | \lambda) = \sum_{i=1}^N f_t(i)$ .

O passo 1 necessita de  $n$  multiplicações, enquanto a recursão necessita um quantitativo de  $n(T-1)(n+1)$  multiplicações e a etapa final requer apenas somas (ALAMINO, 2005). O número total de multiplicações do Forward Procedure é, então,  $n + n(T-1)(n+1)$ , que é polinomial na ordem de 2 em  $n$  e na ordem de 1 em  $T$  (ALAMINO, 2005).

O Backward Procedure é um algoritmo recursivo que é iniciado com uma variável backward  $b_1(i) = P(v_{t+1}, v_{t+2} \dots v_T, q_t = S_i | \lambda)$ . O algoritmo é executado da seguinte forma (PETRUSHIN, 2000; SENA *et al.*, 2016; ALAMINO, 2005):

- Inicialização:  $b_T(i) = 1, 1 \leq i \leq N$ ;
- Recursão:  $b_t(i) = \sum_{j=1}^N a_{ij} e_j(v_{t+1}) b_{t+1}(j), T-1, T-2, \dots, 1, 1 \leq i \leq N$ ;
- Finalização:  $P(V | \lambda) = \sum_{i=1}^N b_1(i) \pi_i e_i(v_1)$ .

O passo 2, relacionado à recursão, necessita de  $2n^2(T-1)$  multiplicações, enquanto o passo 3 necessita de  $2n$  multiplicações (ALAMINO, 2005). O número total de multiplicações do Backward Procedure é  $2n + 2n^2(T-1)$  e, assim como o Forward Procedure, apresenta complexidade polinomial na ordem de 2 em  $n$  e na ordem de 1 em  $T$  (ALAMINO, 2005).

Tanto o Forward Procedure quanto o Backward Procedure são algoritmos que podem ser utilizados para fazer o cálculo eficiente de  $P(V | \lambda)$  e solucionar o primeiro problema canônico dos HMMs (ALAMINO, 2005).

### 3.1.2 Segundo Problema

O segundo dos problemas canônicos que envolvem a modelagem por meio de Modelos Ocultos de Markov é conhecido como o Problema do Reconhecimento e está relacionado a encontrar a melhor sequência de estados ocultos que influenciou na geração dos estados observados do modelo (ALAMINO, 2005). Ou seja, qual sequência de transição de estados é mais provável que tenha conduzido a uma sequência de observações (NGUYEN, 2013).

Para Nguyen (2013), uma estratégia de força bruta nessa situação é uma solução inviável, dado uma grande quantidade de estados. Sendo assim, de acordo com Nguyen (2013), a melhor solução a ser utilizada nessa situação é o Algoritmo de Viterbi (DUGAD; DESAI, 1996).

Dessa forma, para a solução do problema em questão, basta utilizar o algoritmo de Viterbi para maximizar a distribuição de probabilidades do modelo, uma vez que a operação vai retornar a sequência mais provável de estados não observados que influenciam diretamente na geração dos estados observados dentro dos parâmetros definidos pelo modelo (SENA *et al.*, 2016).

O algoritmo possui algumas variáveis de entrada, que basicamente são as variáveis que descrevem o HMM  $\lambda = (S, V, A, B, \pi)$  (PETRUSHIN, 2000; SENA *et al.*, 2016; ALAMINO, 2005):

- Conjunto de estados ocultos  $S = \{s_1, s_2, s_3, \dots, s_n\}$ ;
- Conjunto de estados observáveis  $V = \{v_1, v_2, v_3, \dots, v_n\}$ ;
- Matriz de probabilidades dos estados ocultos do modelo,  $A = \{a_{ij}\}$ , onde  $a_{ij}$  é a probabilidade de transição entre um estado e outro;
- Matriz de probabilidades dos estados observáveis do modelo no estado  $j$ ,  $B = \{b_j(k)\}$ , onde  $b_j(k)$  é a probabilidade de emissão de um símbolo em determinado estado;
- Distribuição inicial de probabilidades dos estados ocultos, representada por  $\pi$ ;

Além das variáveis do HMM, é necessário ainda um vetor  $va$ , que armazena os maiores valores de probabilidades no tempo  $t$ ; e um vetor  $vx$ , que armazena a sequência de estados com maior probabilidade ao longo da execução do algoritmo (SENA *et al.*, 2016).

Dadas essas variáveis como entrada, o Algoritmo de Viterbi é executado como mostra o pseudo-código a seguir (PETRUSHIN, 2000; SENA *et al.*, 2016; ALAMINO, 2005):

---

**Algorithm 1** Algoritmo de Viterbi

---

```

1: para  $i \leftarrow 1$  até  $N$  faça
2:    $va_t(i) = (\pi_i) * (b_i(v_1))$ ;
3:    $vx(i) = 0$ ;
4: fim para
5: para  $j \leftarrow 2$  até  $N$  faça
6:   para  $i \leftarrow 1$  até  $N$  faça
7:      $va_t(j) = \max_{1 \leq i \leq N} (va_{t-1}(i) a_{ij}) * (b_j(v_t))$ ;
8:      $vx_t(j) = \operatorname{argmax}_{1 \leq i \leq N} (va_{t-1}(i) a_{ij}) * (b_j(v_t))$ ;
9:   fim para
10: fim para
11:  $P^* = \max_{1 \leq i \leq N} va_T(i)$ ;
12:  $q_T^* = \operatorname{argmax}_{1 \leq i \leq N} va_T(i)$ ;
13: para  $j \leftarrow N, N-1, \dots$  até  $2$  faça
14:    $q_T^* = vx_{t+1}(q_{t+1}^*)$ ;
15: fim para
16: return  $Q^* = \{q_1^*, q_2^*, q_3^*, \dots, q_n^*\}$ ;

```

---

### 3.1.3 Terceiro Problema

De acordo com [Rabiner \(1989\)](#), o terceiro problema que envolve a modelagem por meio dos HMMs é o mais complexo para ser resolvido. Ele está relacionado a encontrar um método de ajuste dos parâmetros do HMM, de forma a maximizar a probabilidade de uma dada sequência de observações ([RABINER, 1989](#)). Ainda não foi encontrada uma forma de resolver esse problema com baixo custo computacional. No entanto, pode-se utilizar procedimentos iterativos, como o algoritmo de Baum-Welch, onde a probabilidade  $P(O|\lambda)$  é maximizada localmente ([RABINER, 1989](#)).

A ideia do algoritmo de Baum-Welch é fazer uma estimativa do número de transições do estado  $i$  para o  $j$ , e as emissões do símbolo  $k$  no estado  $i$ , tendo como base os parâmetros atuais e a sequência de observação ([PETRUSHIN, 2000](#)). As estimativas são utilizadas para recalculer os parâmetros do modelo. Esse processo recursivo continua até que o critério de parada tenha sido atingido ([PETRUSHIN, 2000](#)).

O algoritmo utiliza as probabilidades de transição e emissão para aproximação dos contadores correspondentes. A probabilidade de transição do estado  $i$  para o estado  $j$  no tempo  $k$  é calculada utilizando a fórmula 3.1 ([PETRUSHIN, 2000](#); [SENA et al., 2016](#)).

$$E(i, j) = P(q_t = i, q_{t+1} = j | V, \lambda) = \frac{f_t(i) a_{ij} e_j(v_{t+1}) b_{t+1}(j)}{P(V | \lambda)} \quad (3.1)$$

O algoritmo é executado da seguinte forma ([PETRUSHIN, 2000](#); [SENA et al., 2016](#)):

- Inicialização: os parâmetros do modelo são escolhidos de forma aleatória. Atribui-se valores a  $A_{ij}$  e  $B_i(t)$ .
- Recursão: cálculo de  $f_i(l)$  e  $b_i(l)$ , para  $i = 1, N$  e  $l = 1, L$ . Calcula-se:

$$A_{ij} = \frac{1}{P(V | \lambda)} \sum_{l=1}^{L-1} f_i(l) a_{ij} e_j(O_{t+1}) b_i(l) b_j(l+1) \quad (3.2)$$

$$B_i(t) = \frac{1}{P(V | \lambda)} \sum_{l|V=t} f_i(l) b_i(l) \quad (3.3)$$

Estimativa dos novos parâmetros do modelo:

$$a_{ij} = \frac{A_{ij}}{\sum_{l=1}^N A_{il}}, e_i(t) = \frac{B_i(t)}{\sum_{l=1}^M E_i(l)}, t = 1, M; i, j = 1, N \quad (3.4)$$

Log do cálculo da verossimilhança.

- Finalização: quando a diferença entre dois valores consecutivos da função de verossimilhança for inferior a um limite imposto ou quando o número máximo de iterações for excedido, o algoritmo deve parar.

$$W_t(j, l) = \left[ \frac{f_t(l) b_t(l)}{P(V | \lambda)} \right] \cdot \left[ \frac{va_{jl} f(v_t; \mu_{jl}, \Sigma_{jl})}{\sum_{m=1}^T va_{jm} f(v_t; \mu_{jm}, \Sigma_{jm})} \right] \quad (3.5)$$



$$VK_{jl} = \frac{\sum_{t=1}^L W_t(j, l)}{\sum_{t=1}^L \sum_{m=1}^T W_t(j, m)} \quad j = \overline{1, N}; l = \overline{1, T} \quad (3.6)$$

$$\mu_{jl} = \frac{\sum_{t=1}^L W_t(j, l) \cdot v_t}{\sum_{t=1}^L W_t(j, m)} \quad (3.7)$$

$$\sum_{jl} = \frac{\sum_{t=1}^L W_t(j, l) \cdot (v_t - \mu_{jl}) \cdot (v_t - \mu_{jl})^T}{\sum_{t=1}^L W_t(j, l)} \quad (3.8)$$

### 3.2 Aprendizagem por Reforço

Quando pensamos sobre a natureza da aprendizagem, a primeira ideia a ocorrer é a de que aprendemos interagindo com nosso ambiente (SUTTON; BARTO, 1998). Uma criança, por exemplo, ao agitar os braços e brincar, está realizando uma conexão sensorial e motora com o ambiente (SUTTON; BARTO, 1998). O exercício dessa conexão produz várias informações sobre causa e efeito, sobre as consequências de suas ações e sobre o que fazer para atingir os objetivos (SUTTON; BARTO, 1998). Dessa forma, a ideia de aprendizagem por meio da interação com o ambiente está relacionada a diversas teorias da aprendizagem.

A Aprendizagem por Reforço (AR) é uma técnica de Aprendizado de Máquina que busca aprender como mapear estados e ações de forma a maximizar um sinal de recompensa (SUTTON; BARTO, 1998). A AR envolve um agente que percebe e atua em um ambiente, realizando ações que afetam o estado do ambiente (ARMSTRONG *et al.*, 2006). O agente recebe recompensas como forma de medida de sucesso de suas ações (ARMSTRONG *et al.*, 2006). Dessa forma, na AR o agente deve aprender qual o melhor comportamento, por meio de "tentativa e erro", interagindo com um ambiente dinâmico (KAELBLING; LITTMAN; MOORE, 1996).

Ao contrário da aprendizagem supervisionada, na AR o agente não tem conhecimento se uma ação é ótima (ARMSTRONG *et al.*, 2006). Ele deve descobrir quais ações produzem melhores recompensas experimentando-as (SUTTON; BARTO, 1998). A ação tomada pode afetar não somente a recompensa imediata, mas também todas as recompensas subsequentes (SUTTON; BARTO, 1998).

A AR é bastante utilizada quando o agente deve atuar em ambientes desconhecidos, onde não se tem conhecimento sobre qual o comportamento correto em determinadas situações (DORÇA, 2012). Dessa forma, ela se difere da aprendizagem supervisionada por não possuir uma representação de pares de entrada/saída. Ao realizar determinada ação, o agente é informado sobre o estado alcançado e adquire experiência sobre suas ações (DORÇA, 2012).

A construção de um agente para atuar na AR envolve a definição das percepções e ações do agente e o reforço do ambiente. Sendo assim, não é preciso definir como o agente deve agir ou qual objetivo deve alcançar, já que todo o aprendizado será conduzido de maneira constante e incremental por intermédio do reforço (DORÇA, 2012).

Isso faz da detecção automática de EA um problema que pode ser modelado utilizando a AR. Na modelagem automática e dinâmica de EA, não existe uma fonte de conhecimento para informar quais os objetivos e ações corretas. Isso ocorre principalmente devido ao não-determinismo e à dificuldade em se modelar regras determinísticas capazes de inferir EA (DORÇA, 2012).

Um exemplo de aplicação da AR para detecção de EA está descrita em Dorça (2012). Na abordagem proposta pelo autor, o sistema seleciona uma estratégia de aprendizagem e avalia o resultado obtido pelo aluno. Se o resultado não for satisfatório, uma abordagem por reforço é aplicada de forma a ajustar os parâmetros que auxiliam o processo de seleção da estratégia de aprendizagem.

A abordagem para AR proposta no trabalho citado é baseada no algoritmo *Q-learning*. O *Q-learning* busca definir a melhor ação, de acordo com uma função de utilidade que mapeia estados e ações a um valor numérico (DORÇA, 2012). No *Q-learning*, a melhor ação a ser executada no estado  $s$  pode ser obtida pela equação 3.9, onde  $\pi^*$  representa a política ótima que maximiza a medida de reforço em longo prazo (IGLESIAS *et al.*, 2009).

$$\pi^*(s) = \operatorname{argmax}_a Q^*(s, a) \quad (3.9)$$

### 3.3 Trabalhos Utilizados como Base para a Proposta

Existem vários trabalhos que buscam solucionar o problema de detecção automática de EA. Destacamos aqui alguns dos trabalhos que foram a base para a presente proposta: Nguyen (2013), Sena *et al.* (2016), Dorça (2012) e Yannibelli, Godoy e Amandi (2006). Todos eles possuem suas vantagens e desvantagens e, basicamente, buscou-se interligar as principais vantagens de cada um dos quatro trabalhos para formar a proposta deste trabalho.

Em seu trabalho, Nguyen (2013) propõe a utilização de HMM para a modelagem de EA, utilizando o Algoritmo de Viterbi para inferir o EA probabilístico. Nguyen (2013) utiliza uma combinação do modelo FSLSM com o modelo de Honey e Mumford para descrição e categorização dos EAs. O modelo construído leva em consideração três dimensões (estados ocultos): Visual/Verbal, Ativista/Refletor e Teórico/Pragmático.

O modelo prevê ainda algumas observações, que compõe a matriz de estados observáveis. Na dimensão Visual/Verbal, os estados observáveis podem ser: texto, figura e vídeo. Na dimensão Ativista/Refletor, os estados observáveis podem ser: teoria, exemplo, exercício, enigma, objeto de aprendizagem de baixa interação, objeto de aprendizagem de média interação ou objeto de aprendizagem de alta interação. Na dimensão Teórico/Pragmático, os estados observáveis são os mesmos da dimensão Ativista/Refletor.

A sequência de observações se torna o parâmetro de entrada para que o Algoritmo de Viterbi possa inferir o EA probabilístico. A abordagem pode ser utilizada também em outros modelos de descrição de EA, como Kolb, Pask, entre outros. Em seu trabalho, Nguyen (2013) não apresenta resultados de uma implementação real da sua proposta.

Já em [Sena et al. \(2016\)](#), foi implementada a abordagem proposta por [Nguyen \(2013\)](#) para detecção de EA, utilizando HMM e o FSLSM. Em seu trabalho, [Sena et al. \(2016\)](#) utilizou a linguagem de programação R para implementar a modelagem de EA por meio de HMM e a inferência do EA probabilístico por meio do Algoritmo de Viterbi. Foi utilizado somente o FSLSM como modelo para descrição de EA. Foi utilizada a metodologia da simulação computacional, onde os dados das interações do estudante com um Ambiente Virtual de Aprendizagem foram gerados aleatoriamente.

Os resultados alcançados pela abordagem implementada por [Sena et al. \(2016\)](#) se mostraram promissores. O algoritmo apresentou uma média de acertos para o FSLSM de 85% para a dimensão Entrada, 86% para a dimensão Processamento, 86% para a dimensão Organização e 84% para a dimensão Percepção.

Enquanto [Nguyen \(2013\)](#) utiliza uma combinação dos modelos de Honey e Mumford e o FSLSM para descrição de EA, [Sena et al. \(2016\)](#) utiliza apenas o FSLSM como modelo. Além disso, o trabalho de [Nguyen \(2013\)](#) não apresenta resultados da implementação do seu algoritmo, diferentemente do proposto em [Sena et al. \(2016\)](#).

Outro importante trabalho é apresentado em [Yannibelli, Godoy e Amandi \(2006\)](#), onde é utilizado um Algoritmo Genético que busca identificar as ações do aluno ao frequentar uma disciplina. Assim, as ações observadas são consideradas como as preferências do estudante e são mapeadas para o FSLSM. No seu algoritmo, [Yannibelli, Godoy e Amandi \(2006\)](#) define a população inicial de cromossomos, de forma que cada cromossomo representa uma combinação de ações. Cada cromossomo dessa população é avaliado de acordo com as ações feitas pelo aluno. Uma nova população é obtida por meio de técnicas de seleção, crossover e mutação ([YANNIBELLI; GODOY; AMANDI, 2006](#)).

[Yannibelli, Godoy e Amandi \(2006\)](#) realizou testes com uma base de dados de um Ambiente Virtual de Aprendizagem real e seu algoritmo mostrou um alto índice de acerto nos estilos de aprendizagem. A taxa de acerto do algoritmo foi de 80% para a dimensão Processamento, 100% para a dimensão Percepção e 100% para a dimensão Organização. Em seu trabalho, [Yannibelli, Godoy e Amandi \(2006\)](#) não considerou a dimensão Entrada do FSLSM, pois a base de dados utilizada não apresentava interações do estudante com o sistema que poderiam ser mapeadas para esta dimensão.

Embora o algoritmo proposto por [Yannibelli, Godoy e Amandi \(2006\)](#) apresente excelentes resultados na detecção de EA, o seu alto tempo de execução pode ser considerado um problema. Além disso, a implementação e adaptação do Algoritmo Genético para detecção de EA não é uma tarefa tão simples de ser realizada.

[Dorça \(2012\)](#) apresenta em seu trabalho uma abordagem que utiliza Aprendizagem por Reforço, onde o processo de atualização do Modelo do Estudante (ME) é feito a partir do desempenho dos estudantes. O desempenho do estudante, por sua vez, é aferido utilizando-se um Processo Estocástico para Simulação do Desempenho do Estudante - PESDE, metodologia criada pelo autor.

O ME é representado por cadeias de Markov, sendo uma para cada dimensão do FSLSM. O ME é formado por uma combinação de objetivos de aprendizagem, estilos de aprendizagem e nível cognitivo (DORÇA, 2012). A abordagem proposta por Dorça (2012) utiliza um algoritmo de reforço para, de acordo com o resultado do desempenho do estudante calculado pelo PESDE, realizar a retroalimentação e atualização do modelo de estudante, representado pelas cadeias de Markov.

Para realizar os testes e validar sua abordagem, Dorça (2012) utilizou a metodologia de simulação computacional. Nos resultados obtidos, foi detectado um alto grau de coesão entre o modelo do estudante probabilístico e o modelo do estudante real, com um baixo custo computacional (DORÇA, 2012).

As metodologias dos trabalhos apresentados utilizam formas diferentes para classificação do estudante em determinado EA. Nguyen (2013), Sena *et al.* (2016) e Yannibelli, Godoy e Amandi (2006) propõe a descoberta do EA por meio de observações das ações do aluno no sistema. Sendo assim, o algoritmo observa o comportamento do estudante no sistema e infere seu EA de acordo com essas observações. Já a proposta apresentada por Dorça (2012) utiliza uma metodologia diferente. Dorça (2012) seleciona uma estratégia de aprendizagem, representada na forma de uma Combinação de Estilos de Aprendizagem (CEA) e, de acordo com o desempenho do aluno, o modelo do estudante é atualizado por meio de uma abordagem por reforço.

A proposta apresentada neste trabalho é uma combinação das abordagens apresentadas por Sena *et al.* (2016), Dorça (2012) e Yannibelli, Godoy e Amandi (2006). Buscou-se unir o que cada uma das três propostas apresenta de melhor e aplicar em uma.

Sendo assim, a base deste trabalho é a abordagem proposta por Sena *et al.* (2016). Desse trabalho foram utilizados os HMMs para a modelagem do estudante e o Algoritmo de Viterbi para inferir o EA probabilístico do estudante. Entende-se que os HMMs conseguem definir de forma clara o modelo do estudante, já que eles consideram as interações do estudante com o sistema de aprendizagem (estados observáveis). São essas interações estudante/sistema que vão possibilitar que o Sistema Tutor Inteligente descubra as características do estudante. Foi utilizado o Algoritmo de Viterbi por ser a solução computacional mais viável para descobrir quais estados ocultos influenciaram na geração dos observáveis do HMM (inferência do EA probabilístico).

Do trabalho do Dorça (2012), utilizou-se a abordagem por reforço proposta. A AR é importante nesse caso, pois os EA não são características estáticas, podendo mudar ao longo do tempo. Além disso, a AR pode corrigir eventuais distorções no modelo do estudante, ao considerar o desempenho do estudante, aferido pelo PESDE. Dessa forma, a AR pode ser entendida como um módulo de correção de EA.

Do trabalho da Yannibelli, Godoy e Amandi (2006), foi utilizada a base de dados apresentada, que contém interações reais de estudantes com um Sistema de Gestão de Aprendizagem. Optou-se pela utilização de uma base real, que contém interações reais de estudantes, por entender que a utilização de metodologia computacional pode muitas vezes não condizer

com a realidade.

### 3.4 Estrutura da Abordagem

Os Sistemas Tutores Inteligentes (STIs) fornecem aos alunos diversos recursos de aprendizagem, como vídeos, fóruns, chat, imagens, entre tantos outros. Esses recursos são conhecidos como Objetos de Aprendizagem (OA). Os STIs armazenam as diversas interações do estudante com os OAs e com o sistema em geral. Dessa forma, essas interações estudante/sistema podem ser pensadas como observações que o STI faz do estudante.

No FSLSM, cada dimensão possui duas subdimensões. As subdimensões, por sua vez, estão associadas a determinadas observações ou Objetos de Aprendizagem. Sendo assim, cada subdimensão de cada dimensão pode ser pensada como um estado que o STI deseja identificar: um estado oculto.

Os HMMs, como visto anteriormente, são estruturas capazes de armazenar probabilidades de transições entre estados observáveis e estados ocultos. Esses estados podem ser modelados por meio de uma matriz de emissão de estados observáveis e uma matriz de transição de estados ocultos.

Podemos então modelar um HMM para cada dimensão do FSLSM, com os seguintes elementos: os estados observáveis do modelo são representados pelas interações do aluno com o sistema; os estados ocultos do modelo são representados pelas subdimensões da dimensão do FSLSM. Para a modelagem, foi utilizada a base de dados disponível em [Yannibelli, Godoy e Amandi \(2006\)](#), que apresenta interações reais de estudantes com um sistema de aprendizagem em oito disciplinas. As interações presentes na base são:

- **Participação em Fóruns:** refere-se à participação do estudante no fórum da disciplina. O estudante pode não participar do fórum, pode apenas ler mensagens, ler e responder mensagens ou enviar mensagens para iniciar uma discussão.
- **Participação em Chats:** refere-se à participação do estudante em chats. O estudante pode não participar de chats, apenas ler as mensagens, ou enviar mensagens e ler as mensagens de outros estudantes.
- **Leitura de Material:** as disciplinas podem apresentar tanto materiais abstratos, como teorias, quanto materiais concretos, como exemplos e aplicações. O estudante pode: observar apenas o material abstrato; observar todo o material abstrato e parte do concreto; observar partes iguais de material abstrato e concreto; observar todo o material concreto e parte do abstrato; ou observar somente o material concreto.
- **Acesso a Exemplos:** as disciplinas oferecem uma série de exemplos sobre o conteúdo abordado. O estudante pode não assistir aos exemplos, assistir todos os exemplos ou assistir parte deles. Sendo assim, foi considerado que o estudante: pode assistir entre 0 e

10% dos exemplos; entre 10% e 30%; entre 30% e 50%; entre 50% e 70%; ou mais que 70% dos exemplos.

- **Exercícios Feitos:** as disciplinas oferecem exercícios aos estudantes para fixação do conteúdo. O estudante pode não fazer nenhum exercício, fazer todos os exercícios ou nenhum deles. Sendo assim, foi considerado que o estudante pode: fazer entre 0% e 10% dos exercícios; entre 10% e 30%; entre 30% e 50%; entre 50% e 70%; ou mais que 70% dos exercícios.
- **Tempo de Entrega do Exame:** as disciplinas ofertam exames, sendo que os estudantes consomem determinado tempo para realizar a entrega da avaliação. Sendo assim, o estudante pode: gastar menos que 40% do tempo determinado para o exame; entre 40% e 50% do tempo; entre 50% e 60% do tempo; entre 60% e 70% do tempo; ou mais que 70% do tempo do exame.
- **Revisão do Exame:** o exame pode ser revisado pelo aluno, como parte do tempo dado para realizar a avaliação. Sendo assim, o estudante pode: usar menos que 5% do tempo dado para revisão; usar entre 5% e 10% do tempo; usar entre 10% e 15% do tempo; usar entre 15% e 20% do tempo; ou usar mais que 20% do tempo dado.
- **Mudança nas Respostas:** os estudantes podem alterar alguma resposta antes da entrega da avaliação. Sendo assim, os estudantes podem: alterar menos que 10% das respostas; alterar entre 10% e 30% das respostas; alterar entre 30% e 50% das respostas; alterar entre 50% e 70% das respostas; ou alterar mais que 70% das respostas.
- **Acesso à Informação:** o acesso aos itens de determinada disciplina podem ser realizados de forma totalmente sequencial (da forma como foram propostos); de forma randômica, fora da ordem em que foram propostos; ou o estudante pode utilizar de uma combinação das duas formas.

Cada uma dessas informações obtidas da base de dados do sistema pode ser categorizada em uma dimensão do FSLSM. Elas irão compor os estados observáveis do modelo, sendo que cada modelo irá representar uma dimensão do FSLSM. Sendo assim, cada dimensão do FSLSM será representada por estados ocultos (subdimensões da dimensão do FSLSM) e por estados observáveis (observações da interação entre o aluno e o sistema).

A dimensão Processamento possui as subdimensões ativo e reflexivo, que na modelagem aqui proposta vão compor os estados ocultos do HMM. Já para os estados observáveis, foram utilizadas duas informações: participação em fórum e participação em chat. Estudantes reflexivos tendem a não participar de chats e fóruns, enquanto os estudantes ativos tendem a participar dos dois (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Percepção possui as subdimensões sensitivo e intuitivo, que compõe os estados ocultos do HMM. Como estados observáveis, foram utilizadas as seguintes informações:



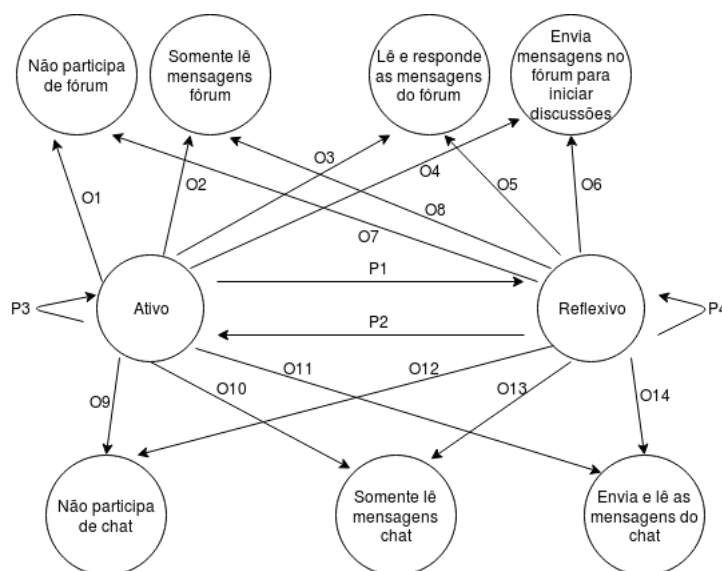
leitura de material, acesso a exemplos, exercícios feitos, tempo de entrega do exame, revisão do exame e mudança nas respostas. Os estudantes sensíveis preferem material concreto, tendem a acessar mais exemplos, fazem todos os exercícios e revisam cuidadosamente as avaliações. Os estudantes intuitivos preferem abstrações, tendem a não acessar muitos exemplos das disciplinas, não fazem todos os exercícios propostos e não realizam uma revisão cuidadosa das avaliações (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Organização possui as subdimensões sequencial e global, que compõem os estados ocultos do HMM. Como estados observáveis, foi utilizada a informação referente à forma de acesso à informação. O estudante sequencial prefere acessar os itens de determinada disciplina de forma sequencial (como foram propostos), enquanto o estudante global prefere acessar o conteúdo de forma randômica e não seguir uma organização linear do conteúdo (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Entrada do FSLSM não será modelada nessa abordagem, pois a base de dados utilizada não possui informações sobre observações relativas à esta dimensão. No entanto, a modelagem da dimensão Entrada pode ser facilmente incorporada à esta abordagem, seguindo a mesma linha das outras dimensões.

Feitas as devidas observações, foram produzidos 3 HMMs, sendo um para a dimensão Processamento, outro para Percepção e outro para Organização. A Figura 12 representa o HMM para a dimensão processamento do FSLSM. As outras dimensões seguem o mesmo padrão.

Figura 12 – Modelo Oculto de Markov para a Dimensão Processamento



Fonte: Próprio Autor.

Na Figura 12, os estados “Ativo” e “Reflexivo” compõem os estados ocultos do modelo. Os estados “Não participa de fórum”, “Somente lê mensagens fórum”, “Lê e responde as mensagens do fórum”, “Envia mensagens no fórum para iniciar discussões”, “Não participa de chat”, “Somente lê mensagens chat”, “Envia e lê as mensagens do chat” compõem os estados

observáveis do modelo.

A transição entre os estados é representada por meio de probabilidades. Dessa forma, as probabilidades P1, P2, P3 e P4 representam a matriz de transição de estados ocultos do modelo. Já as probabilidades O1, O2, O3, O4, O5, O6, O7, O8, O9, O10, O11, O12, O13 e O14 representam a matriz de emissão dos estados observáveis do modelo.

Para cada uma das observações, foi associado um número inteiro para ser identificado pelo algoritmo, conforme as Tabelas 4, 5 e 6, adaptadas de [Yannibelli, Godoy e Amandi \(2006\)](#).

Tabela 4 – Observações relativas à dimensão Percepção e seus respectivos valores

<b>Observação</b>	<b>Valor</b>	<b>Descrição</b>
Leitura de Material	0	Lê somente materiais abstratos
Leitura de Material	1	Lê todo o material abstrato e parte do concreto
Leitura de Material	2	Lê todo o material concreto e abstrato
Leitura de Material	3	Lê todo o material concreto e parte do abstrato
Leitura de Material	4	Lê somente materiais concretos
Acesso a Exemplos	0	Observa menos que 10% dos exemplos
Acesso a Exemplos	1	Observa entre 10% e 30% dos exemplos
Acesso a Exemplos	2	Observa entre 30% e 50% dos exemplos
Acesso a Exemplos	3	Observa entre 50% e 70% dos exemplos
Acesso a Exemplos	4	Observa mais que 70% dos exemplos
Exercícios feitos	0	Faz menos que 10% dos exercícios propostos
Exercícios feitos	1	Faz entre 10% e 30% dos exercícios propostos
Exercícios feitos	2	Faz entre 30% e 50% dos exercícios propostos
Exercícios feitos	3	Faz entre 50% e 70% dos exercícios propostos
Exercícios feitos	4	Faz mais que 70% dos exercícios propostos
Tempo de entrega de avaliações	0	Utiliza menos que 40% do tempo de avaliação
Tempo de entrega de avaliações	1	Utiliza entre 40% e 50% do tempo de avaliação
Tempo de entrega de avaliações	2	Utiliza entre 50% e 60% do tempo de avaliação
Tempo de entrega de avaliações	3	Utiliza entre 60% e 70% do tempo de avaliação
Tempo de entrega de avaliações	4	Utiliza mais que 70% do tempo de avaliação
Revisão de Exame	0	Utiliza menos que 5% do tempo de avaliação
Revisão de Exame	1	Utiliza entre 5% e 10% do tempo de avaliação
Revisão de Exame	2	Utiliza entre 10% e 15% do tempo de avaliação
Revisão de Exame	3	Utiliza entre 15% e 20% do tempo de avaliação
Revisão de Exame	4	Utiliza mais que 20% do tempo de avaliação
Respostas Alteradas	0	Modifica menos que 10% das respostas
Respostas Alteradas	1	Modifica entre 10% e 30% das respostas
Respostas Alteradas	2	Modifica entre 30% e 50% das respostas
Respostas Alteradas	3	Modifica entre 50% e 70% das respostas
Respostas Alteradas	4	Modifica mais que 70% das respostas

Fonte: Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

O Algoritmo de Viterbi é utilizado nos HMMs para solucionar o Problema do Reconhecimento, que está relacionado a descobrir qual a melhor sequência de estados ocultos que influenciou na geração dos estados observáveis ([ALAMINO, 2005](#)). Ele é a solução mais



Tabela 5 – Observações relativas à dimensão Processamento e seus respectivos valores

<b>Observação</b>	<b>Valor</b>	<b>Descrição</b>
Participação em Fórum	0	Não participa de fórum
Participação em Fórum	1	Somente lê as mensagens
Participação em Fórum	2	Lê e responde as mensagens
Participação em Fórum	3	Envia mensagens para iniciar discussões
Participação em Chats	0	Não participa de chats
Participação em Chats	1	Somente lê as mensagens
Participação em Chats	2	Lê e responde as mensagens

Fonte: Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

Tabela 6 – Observações relativas à dimensão Organização e seus respectivos valores

<b>Observação</b>	<b>Valor</b>	<b>Descrição</b>
Acesso à Informação	0	Acessa o material de forma totalmente sequencial
Acesso à Informação	1	Acessa a maior parte do material de forma sequencial e parte de forma global
Acesso à Informação	2	Acessa o material de forma sequencial e global, igualmente
Acesso à Informação	3	Acessa a maior parte do material de forma global e parte de forma sequencial
Acesso à Informação	4	Acessa o material de forma totalmente global

Fonte: Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

viável computacionalmente para se resolver esse problema, dado uma grande quantidade de estados ([NGUYEN, 2013](#)). Na modelagem de EA por meio de HMM, o Algoritmo de Viterbi possui um papel fundamental, já que ele irá realizar a inferência do EA probabilístico do modelo.

O algoritmo proposto foi estruturado para funcionar por meio de disciplinas e alunos. Sendo assim, para cada aluno, em cada disciplina, o HMM é atualizado com as novas observações (atualiza-se a matriz de emissão de observáveis) e o Algoritmo de Viterbi é executado novamente para inferir o EA probabilístico. Caso a performance do aluno seja inferior a 60, o modelo recebe um reforço na matriz de transição de estados ocultos. Nas subseções seguintes serão abordados alguns aspectos importantes da abordagem: cálculo do EA Real, cálculo do reforço e o pseudo-código do algoritmo proposto.

#### 3.4.1 Cálculo do EA Real

A inferência do EA Real do estudante é identificada de acordo com as ações que este realiza no sistema, conforme abordagem proposta por [Yannibelli, Godoy e Amandi \(2006\)](#). As observações (interações do estudante com o sistema) possuem pesos, conforme pode ser visto nas Tabelas 4, 6 e 5. Sendo assim, o EA real do estudante é definido por um somatório desses

pesos. Dependendo do valor obtido pelo somatório, o estudante é classificado com um estilo de aprendizagem correspondente àquela dimensão.

Para a inferência do EA da dimensão Processamento, são consideradas as observações e valores de pesos presentes na Tabela 5. Sendo assim, se a soma dos valores observados for igual a zero, significa que o estudante não participa nem do fórum nem do chat e pode ser considerado reflexivo. De forma análoga, se a soma dos valores observados for igual a 5, significa que o estudante participa tanto do fórum quanto do chat e pode ser considerado ativo (YANNIBELLI; GODOY; AMANDI, 2006). A Tabela 7 mostra os valores de EA para a dimensão Processamento.

Tabela 7 – Inferência do EA Real para dimensão Processamento

Soma dos pesos (S)	EA Correspondente
$0 \leq S \leq 2$	Reflexivo
$3 \leq S \leq 5$	Ativo

Fonte: Adaptado de Yannibelli, Godoy e Amandi (2006)

Para a inferência da dimensão Percepção, são consideradas as observações e valores presentes na Tabela 4. Sendo assim, se a soma dos valores observados for igual a zero, significa que o estudante lê somente material abstrato, vê menos que 10% dos exemplos, faz menos que 10% dos exercícios propostos, utiliza menos que 40% do tempo para fazer as avaliações, usa menos que 5% do tempo para revisar a avaliação e modifica menos que 10% das suas respostas. Ou seja, esse estudante pode ser considerado intuitivo. De forma análoga, se a soma dos valores observados for igual a 24, significa que o estudante lê somente material concreto, vê mais que 70% dos exemplos, faz mais que 70% dos exercícios propostos, utiliza mais que 70% do tempo para fazer as avaliações, usa mais que 20% do tempo para revisar a avaliação e modifica mais que 70% das suas respostas (YANNIBELLI; GODOY; AMANDI, 2006). Assim, esse estudante pode ser considerado sensitivo. Se a soma dos valores observados for um valor intermediário, considera-se o EA como neutro. A Tabela 8 mostra os valores de EA para a dimensão Percepção.

Tabela 8 – Inferência do EA Real para dimensão Percepção

Soma dos pesos (S)	EA Correspondente
$0 \leq S \leq 8$	Intuitivo
$8 \leq S \leq 16$	Neutro
$16 \leq S \leq 24$	Sensitivo

Fonte: Adaptado de Yannibelli, Godoy e Amandi (2006)

Já para a dimensão Organização, são consideradas as observações da Tabela 6. Sendo assim, se a soma dos valores observados é igual a zero, significa que o estudante acessa a informação de forma totalmente sequencial e pode ser considerado como sequencial. De forma análoga, se a soma dos valores observados é igual a 4, significa que o estudante acessa a informação de forma totalmente global e pode ser considerado como global (YANNIBELLI; GO-

DOY; AMANDI, 2006). Se a soma dos valores observados for um valor intermediário, considera-se o EA como neutro. A Tabela 9 mostra os valores de EA para a dimensão Organização.

Tabela 9 – Inferência do EA Real para dimensão Organização

Soma dos pesos (S)	EA Correspondente
$0 \leq S < 2$	Sequencial
$S = 2$	Neutro
$2 < S \leq 4$	Global

Fonte: Adaptado de Yannibelli, Godoy e Amandi (2006)

### 3.4.2 Criação das Matrizes de Estados Observáveis

Cada um dos HMMs propostos (Processamento, Percepção e Organização) apresenta uma matriz de estados observáveis. As matrizes de estados observáveis dos HMMs são estruturas que armazenam as probabilidades de emissão dos estados observáveis do modelo. Sendo assim, para a construção dessas matrizes, foi levado em conta as variações de escala dentro de uma observação, conforme as Tabelas 4, 5 e 6.

A variação foi construída por meio de uma regra de três simples. Tomemos como exemplo a dimensão Processamento e a observação relacionada à participação em fórum. Os valores que essa observação podem assumir são: 0 (não participa do fórum); 1 (somente lê as mensagens do fórum); 2 (lê e responde as mensagens no fórum); 3 (envia mensagem para iniciar discussão no fórum). Esses são os valores disponíveis na Tabela 5.

Assume-se que um estudante que não participa do fórum (0) é 100% do perfil Reflexivo e 0% Ativo, enquanto um estudante que envia mensagens para iniciar discussão no fórum (3) é 100% Ativo e 0% Reflexivo. Sendo assim, a observação "somente lê as mensagens no fórum (1)" pode ser obtida com uma regra de três: 3 corresponde a 100%; logo, 1 corresponderá a 33,34%. Dessa forma, essa observação corresponde a 33,34% do perfil Ativo e a 66,66% do perfil Reflexivo. Seguindo raciocínio semelhante, a observação "lê e responde mensagens no fórum (2)" corresponderá a 66,66% do perfil Ativo e 33,34% Reflexivo. As variações de todas as observações foram construídas seguindo esse raciocínio.

Para a dimensão Processamento, a variação na escala foi produzida conforme Tabela 10 (considera-se ATV como Ativo e REF como Reflexivo).

Para a dimensão percepção, a variação na escala foi produzida conforme Tabela 11 (considera-se SEN como Sensitivo, INT como Intuitivo e NEU como Neutro).

Para a dimensão Percepção, iremos apresentar aqui apenas a escala referente à leitura de material, já que todas as outras observações (acesso a exemplos, exercícios feitos, tempo de entrega de avaliações, revisão de exame e respostas alteradas) seguem o mesmo padrão: a escala varia entre 0 e 4.

Para a dimensão Organização, a variação na escala foi produzida conforme Tabela 12 (considera-se SEQ como Sequencial, GLO como Global e NEU como Neutro):

Tabela 10 – Variação de escala para a dimensão Processamento

<b>Observação</b>	<b>Valor Matriz - Ativo</b>	<b>Valor Matriz - Reflexivo</b>
0 - Não Participa do Fórum	0%	100%
1 - Somente Lê as Mensagens do Fórum	33,34%	66,66%
2 - Lê e Responde as Mensagens do Fórum	66,66%	33,34%
3 - Inicia Discussão no Fórum	100%	0%
0 - Não Participa do Chat	0%	100%
1 - Somente Lê Chat	50%	50%
2 - Lê e Responde Chat	100%	0%

Fonte: Próprio Autor.

Tabela 11 – Variação de escala para a dimensão Percepção

<b>Observação</b>	<b>Valor Matriz - Sensitivo</b>	<b>Valor Matriz - Intuitivo</b>	<b>Valor Matriz - Neutro</b>
0 - Lê somente materiais abstratos	0%	100%	0%
1 - Lê todo material abstrato e parte do concreto	25%	37,5%	37,5%
2 - Lê todo material concreto e abstrato	0%	0%	100%
3 - Lê todo material concreto e parte do abstrato	37,5%	25%	37,5%
4 - Lê somente materiais concretos	100%	0%	0%

Tabela 12 – Variação de escala para a dimensão Organização

<b>Observação</b>	<b>Valor Matriz - Sequencial</b>	<b>Valor Matriz - Global</b>	<b>Valor Matriz - Neutro</b>
0 - Acessa o material de forma totalmente sequencial	100%	0%	0%
1 - Acessa a maior parte do material de forma sequencial e parte de forma global	37,5%	25%	37,5%
2 - Acessa o material de forma sequencial e global, igualmente	0%	0%	100%
3 - Acessa a maior parte do material de forma global e parte de forma sequencial	25%	37,5%	37,5%
4 - Acessa o material de forma totalmente global	0%	100%	0%

Todas as matrizes de estados observáveis foram criadas e atualizadas seguindo as regras acima. Para entender a criação e atualização das matrizes, simularemos a atualização da matriz de observáveis da dimensão Processamento para o estudante 1 na segunda disciplina. O algoritmo possui um vetor responsável por armazenar as observações relacionadas a determinada dimensão e aluno. Para o estudante 1, o vetor de observações da dimensão Processamento após a segunda disciplina possui os seguintes valores: [0, 0, 1, 0].

Os índices pares do vetor (0 e 2) se referem à observação Participação em Fórum, enquanto os índices ímpares do vetor (1 e 3) se referem à observação Participação em Chat. Dessa forma, o primeiro 0 (índice 0 do vetor) indica que o estudante não participou do fórum na primeira disciplina; o segundo 0 (índice 1 do vetor) indica que o estudante não participou de chat na primeira disciplina; o 1 (índice 2 do vetor) indica que o estudante somente leu o fórum na segunda disciplina; o último 0 (índice 3 do vetor) indica que o estudante não participou de chat na segunda disciplina.

A partir do vetor de observações, são aplicadas as regras constantes de variação de escala da dimensão Processamento, vistas acima. Para isso, é realizada uma varredura no vetor e as regras de variação de escala são criadas por meio de condicionais para cada observação.

Para considerar o histórico das observações, cada observação é multiplicada pela sua quantidade de ocorrências no vetor. Sendo assim, para o exemplo do estudante 1 após a segunda disciplina, a matriz ficaria conforme Tabela 13.

Tabela 13 – Matriz de observáveis sem conversão - Estudante 1, disciplina 2

<b>NPF</b>	<b>SLF</b>	<b>LRF</b>	<b>IDF</b>	<b>NPC</b>	<b>SLC</b>	<b>LRC</b>
0	0.3334	0	0	0	0	0
1	0.6666	0	0	2	0	0

Fonte: Próprio Autor.

No entanto, para que o valor das probabilidades fique correto (a soma das probabilidades de cada linha deve ser igual a 1), é necessário dividir os valores pelo somatório das probabilidades da linha da matriz. No exemplo em questão, as probabilidades da primeira linha devem ser divididas por 0.3334, e as probabilidades da segunda linha devem ser divididas por 3.6666. Aplicando-se a conversão (divisão de cada probabilidade pelo somatório das probabilidades de uma linha), a matriz ficaria conforme Tabela 14.

Tabela 14 – Matriz de observáveis - Estudante 1, disciplina 2

<b>NPF</b>	<b>SLF</b>	<b>LRF</b>	<b>IDF</b>	<b>NPC</b>	<b>SLC</b>	<b>LRC</b>
0	1	0	0	0	0	0
0.27	0.18	0	0	0.55	0	0

Fonte: Próprio Autor.

Para fins de simplificação nas tabelas, consideramos “Não Participa do Fórum” como NPF; “Somente Lê Fórum” como SLF; “Lê e Responde ao Fórum” como LRF; “Inicia Discussão

no Fórum” como IDF; “Não Participa do Chat” como NPC; “Somente Lê Chat” como SLC; e “Lê e Responde ao Chat” como LRC.

### 3.4.3 Abordagem por Reforço

Após cada disciplina e o cômputo das observações relacionadas a ela, a matriz de transição dos estados observáveis do HMM é atualizada com os novos valores e o Algoritmo de Viterbi é executado novamente para o cálculo do EA Probabilístico. Caso a performance do aluno seja inferior a 60, um algoritmo de aprendizagem por reforço atualiza a matriz de transição de estados ocultos. Dessa forma, a abordagem por reforço busca aproximar o EA Probabilístico do EA Real do estudante.

O algoritmo de reforço atualiza as probabilidades de transição entre os estados ocultos do HMM. Para o cálculo do reforço, foi implementada uma abordagem proposta em (DORÇA, 2012). Na abordagem, o cálculo do reforço é baseado no algoritmo Q-Learning e é realizado basicamente por meio de duas variáveis: o desempenho simulado do estudante e a distância entre o EA Real e o EA Probabilístico. Esses conceitos serão explicados a seguir.

#### 3.4.3.1 Simulação do Desempenho do Estudante

Em sua abordagem, Dorça (2012) criou o PESDE - Processo Estocástico para Simulação do Desempenho do Estudante. O PESDE é um modelo probabilístico que implementa o aspecto não determinístico existente no processo de aprendizagem e desempenho do estudante (DORÇA, 2012). O modelo permite simular a influência de EA na aprendizagem, sem desconsiderar os diversos outros fatores que podem influenciar no processo de aprendizagem (DORÇA, 2012).

O PESDE utiliza o EA Real para o cálculo do desempenho do estudante. Essa variável é necessária para descobrir a quantidade de preferências não satisfeitas ( $Qpns$ ), que corresponde à quantidade de EA presentes no EA Real e que não são contemplados no EA Probabilístico. A fórmula do PESDE é dada pela equação 3.10.

$$PFM = 100 - (Qpns \times K \times \beta) \quad (3.10)$$

Como  $0 \leq Qpns \leq 5$ , a constante  $K$  foi definida pelo autor com o valor 20, pois dessa forma o valor de PFM estará no intervalo  $0 \leq PFM \leq 100$ . A variável  $\beta$  é um fator aleatório entre 0 e 1, que representa os diversos fatores, além de EA, que podem influenciar no desempenho do estudante (DORÇA, 2012).

A PFM é importante na presente abordagem em dois momentos distintos. No primeiro momento, ela é importante por ser a condição de aplicação do reforço: se a PFM do aluno for inferior a 60, as probabilidades dos estados ocultos do modelo serão ajustadas. Em um segundo momento, a PFM possui um papel importante por ser uma das variáveis utilizadas no cálculo do reforço.

### 3.4.3.2 Distância Entre Estilos de Aprendizagem

A Distância Entre Estilos de Aprendizagem (DEA) é uma variável que armazena a diferença entre os EA de determinada dimensão do EA Probabilístico. Uma DEA baixa (próxima de zero) indica que o EA do estudante ainda é desconhecido. Uma DEA alta indica que o EA do estudante já foi descoberto e que ele possui forte preferência por aquele EA.

Na fórmula da DEA, calcula-se a distância entre os estilos probabilísticos. A distância é obtida utilizando sempre o módulo, para a garantia de obtenção de valores positivos. A fórmula para cálculo da DEA é dada pela equação 3.11.

$$DEA = |di_A - di_B| \quad (3.11)$$

### 3.4.3.3 Cálculo do Reforço

O cálculo do reforço é dado pelas duas variáveis que foram explicadas acima: o desempenho simulado do estudante e a distância entre os estilos de aprendizagem. A fórmula 3.12 a seguir foi utilizada para o cálculo do reforço. Ela retorna um valor entre 0 e 1, que é o valor que irá atualizar as probabilidades de transição entre os estados. Sendo assim, quando a performance do aluno for inferior a 60, o valor do reforço será acrescido de forma a maximizar a probabilidade de transição entre o EA Probabilístico do Modelo do Estudante e outro EA da dimensão. De forma análoga, esse valor será decrescido de forma a minimizar a probabilidade de transição entre outro EA da dimensão e o EA Probabilístico.

$$R = 1/PM \times DEA \quad (3.12)$$

Tomemos como exemplo a dimensão Processamento, um estudante com EA Probabilístico Reflexivo e um valor de PFM abaixo de 60. Como a PFM é menor que 60, um reforço será aplicado no modelo. Se o valor do reforço for 0.02, o algoritmo irá acrescentar 0.02 na transição entre Reflexivo e Ativo e irá decrementar 0.02 na transição entre Reflexivo e Reflexivo. Dessa forma, levando-se em consideração a PFM baixa do aluno e que esta pode ter sido causada pelo Modelo do Estudante não corresponder à realidade, o reforço busca obter uma aproximação de outro EA, que pode ser o EA Real do estudante.

### 3.4.4 Algoritmo Proposto

O algoritmo proposto nesse trabalho inclui duas abordagens distintas: a modelagem por meio dos HMMs e a abordagem por reforço. Para facilitar o entendimento, foi elaborado o pseudo-código do algoritmo, conforme constante no código 3.4.4.

O algoritmo inicia com a leitura dos alunos da base de dados. Foram criados um arquivo .txt para cada um dos alunos. Nos arquivos, constam as informações relacionadas às observações das disciplinas, sendo que cada linha corresponde a uma disciplina e cada coluna corresponde a uma observação. A base de dados será melhor descrita na seção de resultados.

---

**Algorithm 2** Algoritmo Proposto
 

---

```

1: para aluno  $\leftarrow 1$  até N faça
2:   lerAlunoArquivo();
3:   inferirEstiloRealAluno();
4:   criaHMMs();
5:   para disciplina  $\leftarrow 1$  até M faça
6:     atualizaHMMs();
7:     infereEAProbabilistico();
8:     PFM = calculaPerformance();
9:     se PFM < 60 então
10:       calculaReforco();
11:       aplicaReforco();
12:     fim se
13:   fim para
14: fim para

```

---

Após a leitura das informações, o EA Real do aluno é inferido, com base no que foi descrito na subseção 3.4.1. O EA Real é utilizado pelo algoritmo apenas no final da sua execução, para validar a quantidade de acertos que a abordagem obteve (EA probabilístico igual a EA Real). São então criados os HMMs, um para cada uma das dimensões Processamento, Percepção e Organização.

A partir de então, em cada disciplina, os HMMs são atualizados com as observações constantes naquela disciplina (atualiza-se a matriz de emissão de estados observáveis). Os HMMs são atualizados com as observações da nova disciplina, mas sempre mantendo o histórico das observações das disciplinas anteriores.

Após a atualização dos modelos, o EA probabilístico é inferido novamente (por meio do Algoritmo de Viterbi) e a performance do estudante é calculada (conforme subseção 3.4.3.1). Caso a PFM do aluno seja inferior a 60, um reforço é calculado e aplicado na matriz de transição de estados ocultos do modelo (conforme seção 3.4.3).

É importante ressaltar que, embora a PFM seja calculada utilizando as regras constantes em Dorça (2012), a forma como ela é aplicada é diferente. Em Dorça (2012), uma CEA é selecionada e apresentada ao aluno; após esse procedimento, o cálculo do desempenho do aluno é realizado. Neste trabalho, o estudante interage com o sistema e o EA é inferido de acordo com as observações realizadas a partir dessa interação. Após isso, ele é submetido a um processo de avaliação, simulado pelo PESDE, proposto em Dorça (2012).



## 4 RESULTADOS E VALIDAÇÃO DA PROPOSTA

Nesta seção será descrita a base de dados utilizada para validação da proposta, bem como serão apresentados alguns dos resultados obtidos com a execução do algoritmo.

### 4.1 Base de Dados Utilizada

Para os experimentos e validação da proposta de pesquisa, foi utilizada a base de dados apresentada em [Yannibelli, Godoy e Amandi \(2006\)](#). A base de dados consiste nas observações que foram realizadas em um sistema de aprendizagem de determinado curso em oito disciplinas distintas. O curso teve um total de 10 alunos.

São, no total, 10 arquivos do tipo .txt, sendo um arquivo para cada estudante. Os arquivos são carregados pelo algoritmo para a inicialização do aluno e apresentam oito disciplinas - cada disciplina é uma linha do arquivo .txt. Cada linha (ou disciplina) contém nove observações, sendo que cada observação apresenta um valor numérico, conforme Tabelas 4, 5 e 6.

Sendo assim, os arquivos são representados por meio de matrizes, com oito linhas (disciplinas) e nove colunas (observações). As duas primeiras colunas contém observações relacionadas à dimensão Processamento do FSLSM: participação em fórum e participação em chat. As colunas de 3 a 8 contém observações relacionadas à dimensão Percepção do FSLSM: leitura de material, acesso a exemplos, exercícios feitos, tempo de entrega de avaliações, revisão de exame e respostas alteradas. Por fim, a última coluna apresenta observações relacionadas à dimensão Organização do FSLSM: acesso à informação. Um exemplo de conteúdo constante no arquivo .txt do estudante pode ser visto na Tabela 15.

Tabela 15 – Observações relacionadas ao segundo estudante

Disciplina	Obs1	Obs2	Obs3	Obs4	Obs5	Obs6	Obs7	Obs8	Obs9
1	2	2	4	3	3	4	3	1	0
2	1	2	4	4	3	3	3	1	0
3	2	2	4	3	3	4	3	1	0
4	2	2	4	3	3	4	3	1	0
5	1	2	4	4	3	3	3	1	0
6	1	2	4	4	3	3	3	1	0
7	2	2	4	3	3	4	3	1	0
8	2	2	4	3	3	4	3	1	0

Fonte: Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

Pela leitura da Tabela 15 percebe-se, por exemplo, que as observações do segundo aluno na disciplina 1 são: lê e responde as mensagens do fórum (Obs1); lê e responde as mensagens do chat (Obs2); somente lê material concreto (Obs3); observa entre 50% e 70% dos exemplos (Obs4); faz entre 50% e 70% dos exercícios propostos (Obs5); utiliza mais que 70%

do tempo dado para entrega de avaliação (Obs6); utiliza entre 15% e 20% do tempo para revisar a avaliação (Obs7); modifica entre 10% e 30% das respostas (Obs8); acessa a informação de maneira completamente sequencial (Obs9). As outras observações, referentes a outros estudantes e outras disciplinas, seguem a mesma associação. Todas as dez matrizes, que representam os arquivos .txt e as observações relacionadas aos dez alunos, estão disponíveis na seção dos Anexos.

## 4.2 Resultados Obtidos

Com o objetivo de comparar os resultados dessa abordagem com a proposta por [Yannibelli, Godoy e Amandi \(2006\)](#), foram implementados os dois algoritmos: o Algoritmo Genético e o algoritmo descrito neste trabalho. Para facilitar a programação dos algoritmos, foi utilizado o padrão de projetos Strategy e o paradigma de Orientação a Objetos. O Strategy é um *design pattern* que define uma família de algoritmos e encapsula cada uma delas, tornando-as intercambiáveis ([GAMMA et al., 2000](#)). Com o uso do Strategy e do paradigma de Orientação a Objetos, a implementação dos algoritmos e a execução dos testes se torna mais fácil.


Os algoritmos foram implementados utilizando a linguagem de programação Java. O ambiente gráfico para desenvolvimento (IDE - Integrated Development Environment) utilizado foi o Netbeans, na sua versão 8.2. O sistema operacional utilizado tanto para o desenvolvimento quanto para os testes foi o Linux Ubuntu 16.04 LTS.

A execução do algoritmo proposto retorna o EA Real (EAr) do aluno, que é inferido utilizando as regras constantes na seção [3.4.1](#); e o EA Probabilístico (EAp) do estudante, obtido por meio da inferência realizada pelo Algoritmo de Viterbi, aplicado aos HMMs. Caso o EA Probabilístico seja igual ao EA Real ao final da execução do algoritmo, considera-se que a abordagem proposta consegue inferir corretamente o EA do estudante.

As Figuras [13](#), [14](#) e [15](#) apresentam as inferências realizadas pelo algoritmo para os estudantes 9, 10 e 4, após cada uma das 8 disciplinas. Pela análise dos gráficos é possível perceber, para cada disciplina, se o EA Probabilístico (inferido por meio do Algoritmo de Viterbi) é igual ao EA Real. Nos casos onde os EAs Probabilístico e Real não coincidem, é apresentado o valor 1; nos casos onde os EAs coincidem, é apresentado o valor 2. Dessa forma, podemos perceber o comportamento do algoritmo e a convergência do mesmo ao longo de sua execução.


Para o estudante 9, por exemplo, percebe-se que todas as dimensões foram inferidas corretamente na primeira disciplina. As dimensões Percepção e Organização continuaram a ser inferidas corretamente ao longo das próximas disciplinas, até a oitava e última disciplina. Já a dimensão Processamento foi inferida corretamente apenas na primeira e quarta disciplina. Nas outras seis disciplinas, devido às novas observações realizadas e ao reforço aplicado no ME, a inferência do EA Probabilístico acabou ficando equivocada após a finalização das 8 disciplinas. Esse é um dos três casos onde o algoritmo não conseguiu inferir corretamente o EA do estudante ao final das 8 disciplinas, conforme será visto na Tabela [16](#).

Figura 13 – Inferências de EA para o estudante 9, por disciplina



Fonte: Próprio Autor.

Figura 14 – Inferências de EA para o estudante 10, por disciplina




Fonte: Próprio Autor.

Para o estudante 10 (Figura 14), percebe-se que o algoritmo não alterou seu comportamento ao longo das disciplinas. As dimensões Processamento e Organização foram inferidas corretamente desde a primeira disciplina. Já o EAp da dimensão Percepção foi inferido incorretamente desde a primeira disciplina, mantendo o comportamento até o final das 8 disciplinas. Esse é outro dos três casos onde o algoritmo não conseguiu inferir corretamente o EA do estudante ao final das 8 disciplinas, conforme será visto na Tabela 16.

Já para o estudante 4 (Figura 15), percebe-se que existe uma correspondência entre EA Probabilístico e EA Real desde a primeira disciplina, para todas as dimensões. A inferência do EA Probabilístico pelo Algoritmo de Viterbi para este estudante manteve um padrão durante toda a execução do algoritmo.

Os resultados obtidos pela execução do algoritmo para os dez estudantes constam na Tabela 16. Os resultados presentes na tabela são frutos da inferência realizada por estudante, após a finalização das 8 disciplinas. Para simplificação, considera-se Ativo como ATV, Reflexivo como REF, Sensitivo como SEN, Intuitivo como INT, Sequencial como SEQ, Global como GLB e Neutro como NEU.

Figura 15 – Inferências de EA para o estudante 4, por disciplina



Fonte: Próprio Autor.

Tabela 16 – Resultados: EA Real e EA Probabilístico de cada estudante

Estudante	EAr Proc.	EAp Proc.	EAr Percep.	EAp Percep.	EAr Org.	EAp Org.
1	REF	REF	INT	INT	SEQ	SEQ
2	ATV	ATV	SEN	SEN	SEQ	SEQ
3	REF	REF	<b>INT</b>	<b>SEN</b>	GLB	GLB
4	REF	REF	NEU	NEU	GLB	GLB
5	ATV	ATV	SEN	SEN	SEQ	SEQ
6	REF	REF	INT	INT	GLB	GLB
7	ATV	ATV	NEU	NEU	NEU	NEU
8	REF	REF	INT	INT	NEU	NEU
9	<b>ATV</b>	<b>REF</b>	SEN	SEN	SEQ	SEQ
10	ATV	ATV	<b>NEU</b>	<b>SEN</b>	SEQ	SEQ

Fonte: Próprio Autor

Percebe-se, pela análise da Tabela 16, que a abordagem proposta consegue inferir os EA dos estudantes com um bom nível de acerto. Na dimensão processamento, a abordagem conseguiu inferir 90% dos EA corretamente. Na dimensão percepção, o algoritmo inferiu 80% dos EA corretamente. Na dimensão Organização, 100% dos EA foram inferidos corretamente.

A título de comparação, em seu trabalho, onde é utilizado um Algoritmo Genético para detectar os EA, [Yannibelli, Godoy e Amandi \(2006\)](#) obteve resultados semelhantes: na dimensão processamento, o algoritmo inferiu 80% dos EA corretamente; na dimensão percepção, 100% dos EA foram inferidos corretamente; na dimensão organização, 100% dos EA foram inferidos corretamente.

Entre a abordagem proposta por [Yannibelli, Godoy e Amandi \(2006\)](#) e a abordagem proposta neste trabalho, a diferença nos resultados se encontra nas dimensões percepção e processamento. Na dimensão percepção, o Algoritmo Genético obteve 100% de acerto, enquanto o algoritmo aqui proposto obteve 80% de acerto. Em contrapartida, na dimensão processamento o Algoritmo Genético obteve 80% de acerto, enquanto a presente proposta obteve 90% de acerto para esta dimensão.

De acordo com a Tabela 16, apenas em dois casos o algoritmo não inferiu o EA para a dimensão Percepção corretamente. São os casos do estudante 3, onde o EAr é "Intuitivo" e o EAp inferido foi "Sensitivo"; e o estudante 10, onde o EAr é "Neutro" e o EAp inferido foi "Sensitivo". Na dimensão Processamento, para o aluno 9 o EAr é "Ativo" e o EAp inferido foi "Reflexivo". Os três casos se encontram em destaque na Tabela 16.

Uma outra forma de analisar os dados obtidos é verificando a quantidade total de inferências, para os 10 estudantes, nas oito disciplinas. Quando analisamos todas as inferências de EA após cada disciplina, é possível perceber que o algoritmo apresenta uma alta taxa de acerto nas inferências. São, no total, 24 inferências por aluno: uma inferência por disciplina para cada uma das 3 dimensões do FSLSM, sendo que no total existem 8 disciplinas. A base é composta por 10 estudantes, totalizando 240 inferências.

Levando-se em consideração os erros nas inferências (foram 6 erros de inferência para o aluno 3, na dimensão Percepção; 8 erros de inferência para o aluno 10, na dimensão Percepção; 6 erros de inferência para o aluno 9, na dimensão Processamento), o número total de erros é de 20 em 240 inferências. Isso representa uma taxa média de aproximadamente 8,33% das inferências. Significa que o algoritmo consegue inferir o EA corretamente em 91,67% dos casos.

Em termos de tempo de execução, a diferença entre os dois algoritmos é significativa. O Algoritmo Genético proposto por [Yannibelli, Godoy e Amandi \(2006\)](#) apresenta um tempo médio entre 132000 e 134000 milissegundos para convergir para os melhores resultados, com uma população inicial de 10000 cromossomos. Já o algoritmo proposto nesse trabalho apresenta um tempo médio de convergência muito menor: entre 80 e 150 milissegundos. Para o cálculo do tempo médio de execução, foi utilizada o método java `System.currentTimeMillis()`, que retorna o tempo atual em milissegundos.

Existem alguns fatores que podem explicar essa diferença nos tempos de execução dos dois algoritmos. Para convergir, o Algoritmo Genético utiliza uma população inicial de cromossomos muito grande: 10000 cromossomos. Em seu trabalho, [Yannibelli, Godoy e Amandi \(2006\)](#) realiza também testes com uma população menor, de 5000 cromossomos. No entanto, os resultados obtidos na inferência do EA não foram tão satisfatórios como os obtidos com a população de 10000 cromossomos. O Algoritmo Genético utiliza ainda técnicas de seleção (roleta), cruzamento (cruzamento de dois pontos) e mutação simples, que elevam o tempo de execução do programa. O tamanho da população inicial do Algoritmo Genético, bem como a quantidade de métodos utilizados para garantir a convergência para bons resultados, pode estar influenciando diretamente no tempo de execução do mesmo.

Em contrapartida, o algoritmo proposto nesse trabalho utiliza HMMs, que são modelos matemáticos extremamente simples e de fácil representação computacional. Além disso, a inferência do EA probabilístico, que poderia ser o problema dessa abordagem, não o é, visto que o Algoritmo de Viterbi otimiza a busca nos estados observáveis e o mapeamento nos estados ocultos.



## 5 CONSIDERAÇÕES FINAIS

Diante da necessidade de se construir sistemas adequados para a EaD, que consigam se adaptar aos estudantes de acordo com suas preferências, a detecção dos EAs se tornou um importante tópico nas pesquisas da Informática aplicada na Educação. A detecção deve ser automática, para evitar auto concepções imprecisas por parte do estudante.

Dessa forma, o objetivo principal do presente trabalho foi apresentar um modelo computacional que seja capaz de inferir e armazenar os EAs dos estudantes, baseado no modelo de descrição de EA apresentado por [Felder, Silverman \*et al.\* \(1988\)](#), o FSLSM. Definiu-se como premissa que o modelo deveria ser adaptável e passível de implementação em um STI, onde seria possível a individualização do estudante e a recomendação de materiais didáticos adaptados ao seu perfil.

Dessa forma, o modelo computacional proposto no presente trabalho utiliza HMMs para modelar EA. A inferência dos EA é realizada por meio do Algoritmo de Viterbi e a correção dos EA é feita por meio de um algoritmo de aprendizagem por reforço. A abordagem se mostrou eficiente e de fácil adaptação à estrutura do FSLSM. Além disso, pelo fato de EA serem considerados como tendências ([KINSHUK; GRAF, 2009](#)), a modelagem por meio de matrizes de probabilidades se adapta muito bem ao problema.

A base de dados utilizada para testes do modelo é composta por observações das interações de estudantes com um sistema de aprendizagem em oito disciplinas. Sendo assim, a modelagem por meio de HMMs é muito eficiente, visto que sua estrutura consegue armazenar os estados observáveis e suas probabilidades de transição, por meio da matriz de emissão de estados observáveis.

A inferência dos EA por meio do Algoritmo de Viterbi é, além de simples, eficiente. A abordagem por reforço implementada no modelo torna-se importante para corrigir automaticamente eventuais distorções no EA inferido, além de aproximar o EA Probabilístico do EA Real. A abordagem apresenta, ainda, um baixo custo computacional.

Os resultados obtidos se mostraram satisfatórios, com uma boa taxa de correspondência entre EA Real e EA Probabilístico, conforme discutido no capítulo 4. Em média, o algoritmo obteve uma taxa de acerto de 100% para a dimensão Processamento, 80% para a dimensão Percepção e 100% para a dimensão Organização, que demonstra um futuro promissor para a implementação da proposta em um sistema de aprendizagem real.

### 5.1 Contribuições

As contribuições do trabalho se encontram em algumas especificidades da sua implementação. Primeiramente, a utilização dos HMMs em conjunto com uma abordagem por reforço permite que o modelo do estudante seja constantemente atualizado e corrigido, de acordo

com seu desempenho (nota). A abordagem por reforço considera, então, o desempenho do aluno, que pode estar sendo influenciado por uma inconsistência no seu modelo de estudante. Em segundo momento, a utilização de uma base de dados de estudantes permite obter um resultado mais realístico do que uma simulação computacional, onde os dados são gerados aleatoriamente.

Soma-se a esses pontos a utilização de HMMs para descrição de EA e o Algoritmo de Viterbi para inferência de EA, que são comprovadamente bons para modelagem do problema, além de apresentarem bons resultados, conforme trabalhos de [Nguyen \(2013\)](#) e [Sena \*et al.\* \(2016\)](#). Todas essas abordagens funcionando de maneira simultânea resultam nos excelentes resultados apresentados.

## 5.2 Trabalhos Futuros

Com o modelo computacional e os resultados apresentados, novas oportunidade de trabalho são vislumbradas. Como trabalhos futuros, destacam-se algumas possibilidades:

- a utilização do algoritmo em uma base de dados com mais estudantes, que contemple a dimensão Entrada do FSLSM, e a execução do modelo proposto nessa base;
- utilização do modelo proposto para levantamento dos EAs dos estudantes de uma instituição de ensino;
- utilização dos HMMs como estrutura para recomendação de objetos de aprendizagem para estudantes;
- implementação e validação do modelo proposto em um Ambiente Virtual de Aprendizagem, com alunos reais.



## REFERÊNCIAS

- AL-AZAWEI, A.; BADII, A. State of the art of learning styles-based adaptive educational hyper-media systems (LS-BAEHSs). **International Journal of Computer Science & Information Technology**, Academy & Industry Research Collaboration Center (AIRCC), v. 6, n. 3, p. 1, 2014.
- ALAMINO, R. C. **Aprendizado em modelos de Markov com variáveis de estado escondidas**. Tese (Doutorado) — Universidade de São Paulo, 2005.
- ALVES, J. R. M. **Educação à distância e as novas tecnologias de informação e aprendizagem**. 2001. Disponível em: <http://www.conhecer.org.br/download/cp/NOVAS%20TECNOLOGIAS/M1/leitura%20anexa%206.pdf>. Acesso em: 20 out. 2017.
- AMARAL, B.; BORBA, M. C.; MALHEIROS, A. P. S. **Educação a Distância online**. [S.l.]: Belo Horizonte: Autêntica, 2007.
- AMIR, E. S.; SUMADYO, M.; SENSUSE, D. I.; SUCAHYO, Y. G.; SANTOSO, H. B. Automatic detection of learning styles in learning management system by using literature-based method and support vector machine. In: IEEE. **Advanced Computer Science and Information Systems (ICACSIS), 2016 International Conference on**. [S.l.], 2016. p. 141–144.
- ANARAKI, F. Developing an effective and efficient e-learning platform. **International Journal of the computer, the internet and management**, v. 12, n. 2, p. 57–63, 2004.
- ARMSTRONG, W.; CHRISTEN, P.; MCCREATH, E.; RENDELL, A. P. Dynamic algorithm selection using reinforcement learning. In: IEEE. **Integrating AI and Data Mining, 2006. AIDM'06. International Workshop on**. [S.l.], 2006. p. 18–25.
- AVGERIOU, P.; PAPASALOUIROS, A.; RETALIS, S.; SKORDALAKIS, M. Towards a pattern language for learning management systems. **Educational Technology & Society**, JSTOR, v. 6, n. 2, p. 11–24, 2003.
- BAKER, R.; ISOTANI, S.; CARVALHO, A. Mineração de dados educacionais: Oportunidades para o brasil. **Brazilian Journal of Computers in Education**, v. 19, n. 02, p. 3, 2011.
- BANDURA, A.; AZZI, R. G.; POLYDORO, S. A. **Teoria social cognitiva: conceitos básicos**. [S.l.]: Artmed Editora, 2009.
- BAUM, L. E.; EAGON, J. A. *et al.* An inequality with applications to statistical estimation for probabilistic functions of markov processes and to a model for ecology. **Bull. Amer. Math. Soc**, v. 73, n. 3, p. 360–363, 1967.
- BAUM, L. E.; PETRIE, T. Statistical inference for probabilistic functions of finite state markov chains. **The annals of mathematical statistics**, JSTOR, v. 37, n. 6, p. 1554–1563, 1966.
- BITTENCOURT, I. M.; MERCADO, L. P. L. Evasão nos cursos na modalidade de educação a distância: estudo de caso do curso piloto de administração da ufal/uab. **Revista Ensaio: Avaliação e Políticas Públicas em Educação**, v. 22, n. 83, p. 465–504, 2014.
- BORDENAVE, J. D.; PEREIRA, A. M. **Estratégias de ensino-aprendizagem**. [S.l.]: Vozes, 2014.

BOSTRÖM, L. Students' learning styles compared with their teachers' learning styles in secondary schools. **Institute for Learning Styles Journal**, v. 1, n. 1, p. 17–38, 2011.

BOTSIOS, S.; GEORGIU, D.; SAFOURIS, N. Contributions to adaptive educational hypermedia systems via on-line learning style estimation. **Educational Technology & Society**, JSTOR, v. 11, n. 2, p. 322–339, 2008.

BRASIL. **Lei de Diretrizes e Bases da educação Nacional**. Diário Oficial da União, Brasília, Seção 1, p. 27839, 1996. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/leis/L9394.htm](http://www.planalto.gov.br/ccivil_03/leis/L9394.htm).

BRASIL. **Decreto 5.622**. 2005. Disponível em: <http://portal.mec.gov.br/sesu/arquivos/pdf/portarias/dec5.622.pdf>.

BRUSILOVSKY, P. Methods and techniques of adaptive hypermedia. **User modeling and user-adapted interaction**, Springer, v. 6, n. 2-3, p. 87–129, 1996.

BRUSILOVSKY, P. Adaptive educational hypermedia. In: **International PEG Conference**. [S.l.: s.n.], 2001. v. 10, p. 8–12.

BRUSILOVSKY, P. **User modeling and user-adapted interaction**. [S.l.]: Kluwer Academic Publishers, the Netherlands, 2001.

BRUSILOVSKY, P.; MILLÁN, E. User models for adaptive hypermedia and adaptive educational systems. In: SPRINGER-VERLAG. **The adaptive web**. [S.l.], 2007. p. 3–53.

BRUSILOVSKY, P.; PEYLO, C. Adaptive and intelligent web-based educational systems. **International Journal of Artificial Intelligence in Education (IJAIED)**, v. 13, p. 159–172, 2003.

CABADA, R. Z.; ESTRADA, M. L. B.; GARCIA, C. A. R. EDUCA: A web 2.0 authoring tool for developing adaptive and intelligent tutoring systems using a Kohonen network. **Expert Systems with Applications**, Elsevier, v. 38, n. 8, p. 9522–9529, 2011.

CARBONELL, J. R. Ai in cai: An artificial-intelligence approach to computer-assisted instruction. **IEEE transactions on man-machine systems**, IEEE, v. 11, n. 4, p. 190–202, 1970.

CASTAÑON, G. A. **O que é cognitivismo: fundamentos filosóficos**. [S.l.]: EPU, 2007.

CAVELLUCCI, L. C. B. *et al.* **Estudo de um ambiente de aprendizagem baseado em mídia digital: uma experiência na empresa**. Tese (Doutorado) — Universidade Estadual de Campinas, 2003.

CHA, H. J.; KIM, Y. S.; PARK, S. H.; YOON, T. B.; JUNG, Y. M.; LEE, J.-H. Learning styles diagnosis based on user interface behaviors for the customization of learning interfaces in an intelligent tutoring system. In: SPRINGER. **International Conference on Intelligent Tutoring Systems**. [S.l.], 2006. p. 513–524.

CHANG, Y.-C.; KAO, W.-Y.; CHU, C.-P.; CHIU, C.-H. A learning style classification mechanism for e-learning. **Computers & Education**, Elsevier, v. 53, n. 2, p. 273–285, 2009.

COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. *et al.* **Learning styles and pedagogy in post-16 learning: A systematic and critical review**. [S.l.]: Learning and Skills Research Centre London, 2004.

DEVEDŽIĆ, V. **Semantic Web and Education. Integrated Series in Information Systems, vol. 12.** [S.l.]: Springer, US, 2006.

DORÇA, F. A. **Uma abordagem estocástica baseada em Aprendizagem por Reforço para modelagem automática e dinâmica de Estilos de Aprendizagem de Estudantes em Sistemas Adaptativos e Inteligentes para Educação a Distância.** Tese (Doutorado), 2012.

DUGAD, R.; DESAI, U. B. A tutorial on hidden markov models. **Signal Processing and Artificial Neural Networks Laboratory, Dept of Electrical Engineering, Indian Institute of Technology, Bombay Technical Report No.: SPANN-96.1**, 1996.

Essaid El Bachari, E. H. A.; El Adnani, M. **E-LEARNING PERSONALIZATION BASED ON DYNAMIC LEARNERS' PREFERENCE.** Citeseer, 2011.

FALCI, S. H.; VIVAS, A.; ASSIS, L.; PITANGUI, C. Uma nova abordagem para aplicação de reforço em sistemas automáticos e adaptativos de detecção de estilos de aprendizagem. **Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação**, v. 1, n. 6, 2017.

FELDER, R. M.; BRENT, R. Understanding student differences. **Journal of engineering education**, Wiley Online Library, v. 94, n. 1, p. 57–72, 2005.

FELDER, R. M.; SILVERMAN, L. K. *et al.* Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988.

FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. **International journal of engineering education**, v. 21, n. 1, p. 103–112, 2005.

FRAGELLI, R. R. **Uma abordagem de redes quantizadas e objetos multiformes para modelagem de domínio em sistemas de tutoria inteligentes.** Tese (Doutorado) — Universidade de Brasília, 2011.

GABARDO, P.; QUEVEDO, S. R. de; ULBRICHT, V. R. Estudo comparativo das plataformas de ensino-aprendizagem. **Encontros Bibli: revista eletrônica de biblioteconomia e ciência da informação**, Universidade Federal de Santa Catarina, n. Especial 2, 2010.

GAMMA, E.; HELM, R.; JOHNSON, R. E.; VLISSIDES, J. **Design patterns: elements of reusable object-oriented software.** [S.l.]: Braille Jymico Incorporated, 2000.

GARCIA, P.; AMANDI, A.; SCHIAFFINO, S.; CAMPO, M. Using Bayesian networks to detect students' learning styles in a web-based education system. **Proc of ASAI, Rosario**, p. 115–126, 2005.

GARCIA, P.; AMANDI, A.; SCHIAFFINO, S.; CAMPO, M. Evaluating Bayesian networks precision for detecting students learning styles. **Computers & Education**, Elsevier, v. 49, n. 3, p. 794–808, 2007.

GARCIA, P.; SCHIAFFINO, S.; AMANDI, A. An enhanced Bayesian model to detect students' learning styles in Web-based courses. **Journal of Computer Assisted Learning**, Wiley Online Library, v. 24, n. 4, p. 305–315, 2008.

GILBERT, J. E.; HAN, C. Y. Adapting instruction in search of 'a significant difference'. **Journal of Network and Computer applications**, Elsevier, v. 22, n. 3, p. 149–160, 1999.

GIRAFFA, L. M. M. **Uma arquitetura de tutor utilizando estados mentais**. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 1999.

GOMIDE, F.; GUDWIN, R. R.; TANSCHKEIT, R. Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações. In: **Proc. 6 th IFSA Congress-Tutorials**. [S.l.: s.n.], 1995. p. 1–38.

GONG, W.; WANG, W. Application research of support vector machine in e-learning for personality. In: IEEE. **Cloud Computing and Intelligence Systems (CCIS), 2011 IEEE International Conference on**. [S.l.], 2011. p. 638–642.

GRAESSER, A. C.; CONLEY, M. W.; OLNEY, A. Intelligent tutoring systems. *American Psychological Association*, v. 3, p. 451–473, 2012.

GRAF, S.; IVES, C. *et al.* A flexible mechanism for providing adaptivity based on learning styles in learning management systems. In: IEEE. **Advanced Learning Technologies (ICALT), 2010 IEEE 10th International Conference on**. [S.l.], 2010. p. 30–34.

GRAF, S.; LIN, T. *et al.* Analysing the relationship between learning styles and cognitive traits. In: IEEE. **Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference on**. [S.l.], 2007. p. 235–239.

GRAF, S.; LIU, T.-C. *et al.* Supporting teachers in identifying students' learning styles in learning management systems: An automatic student modelling approach. **Journal of Educational Technology & Society**, International Forum of Educational Technology & Society, v. 12, n. 4, p. 3, 2009.

GRANITO, R. A. N. **Educação a distância e estilos de aprendizagem: elaboração de um protocolo de qualidade para ambientes virtuais de ensino**. Tese (Doutorado) — Universidade de São Paulo, 2008.

HONEY, P.; MUMFORD, A. The manual of learning styles. **Peter Honey Publications**, 1992.

HONEY, P.; MUMFORD, A. **The learning styles helper's guide**. [S.l.]: Peter Honey Maidenhead, 2000.

IGLESIAS, A.; MARTÍNEZ, P.; ALER, R.; FERNÁNDEZ, F. Learning teaching strategies in an adaptive and intelligent educational system through reinforcement learning. **Applied Intelligence**, Springer, v. 31, n. 1, p. 89–106, 2009.

JISC. **Effective practice with e-learning: a good practice guide in designing for learning**. 2004. Disponível em: <http://workspace.unpan.org/sites/Internet/Documents/UNPAN93466.pdf>. Acesso em: 22 out. 2017.

KAELBLING, L. P.; LITTMAN, M. L.; MOORE, A. W. Reinforcement learning: A survey. **Journal of artificial intelligence research**, v. 4, p. 237–285, 1996.

KINSHUK, L. T. C.; GRAF, S. Coping with mismatched courses: students' behaviour and performance in courses mismatched to their learning styles. **Educational Technology Research and Development**, v. 57, n. 6, p. 739–752, 2009.

KIRSCHNER, P. A.; MERRIËNBOER, J. J. van. Do learners really know best? urban legends in education. **Educational psychologist**, Taylor & Francis, v. 48, n. 3, p. 169–183, 2013.

KOCH, N. P. Software engineering for adaptive hypermedia systems: reference model, modeling techniques and development process. **Ph. DThesis, Verlag Uni-Druck, Munich**, 2001.

KOLB, D. A.; BOYATZIS, R. E.; MAINEMELIS, C. **Experimental Learning: Experience as the source of learning and development**. [S.l.]: Prentice Hall Englewood, 1984.

KOLB, D. A.; BOYATZIS, R. E.; MAINEMELIS, C. *et al.* Experiential learning theory: Previous research and new directions. **Perspectives on cognitive, learning, and thinking styles**, v. 1, n. 8, p. 227–247, 2001.

LEE, K.-F.; HON, H.-W.; HWANG, M.-Y.; HUANG, X. Speech recognition using hidden markov models: a cmu perspective. **Speech Communication**, Elsevier, v. 9, n. 5-6, p. 497–508, 1990.

LIBÂNEO, J. C. **Didática**. [S.l.]: Cortez Editora, 1994.

LIMA, A. I. A. d. O. *et al.* **Estilos de aprendizagem segundo os postulados de David Kolb: uma experiência no curso de odontologia da UNOESTE**. Tese (Doutorado) — Universidade do Oeste Paulista, 2007.

LIU, T.-C.; GRAF, S. *et al.* Coping with mismatched courses: students' behaviour and performance in courses mismatched to their learning styles. **Educational Technology Research and Development**, Springer, v. 57, n. 6, p. 739–752, 2009.

LO, J.-J.; CHAN, Y.-C.; YEH, S.-W. Designing an adaptive web-based learning system based on students' cognitive styles identified online. **Computers & Education**, Elsevier, v. 58, n. 1, p. 209–222, 2012.

LOINAZ, M. U. Sistemas inteligentes en el ámbito de la educación. **Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial**, Asociación Española para la Inteligencia Artificial, v. 5, n. 12, 2001.

MANGHIRMALANI, P.; PANTHAKY, Z.; JAIN, K. Learning disability diagnosis and classification-A soft computing approach. In: IEEE. **Information and Communication Technologies (WICT), 2011 World Congress on**. [S.l.], 2011. p. 479–484.

MATOS, C. C. C. **Recomendações personalizadas de alunos em sistemas de hipermídia adaptativa educacional usando Data Mining**. Tese (Doutorado) — Instituto Politécnico do Porto. Instituto Superior de Engenharia do Porto., 2013.

MAYER, R. E. **El futuro de la psicología cognitiva**. [S.l.]: Madrid: Alianza Psicología, 1985.

MIZUKAMI, M. d. G. N. **Ensino: as abordagens do processo**. [S.l.]: Editora Pedagógica e Universitária, 1986.

MOORE, M. G.; KEARSLEY, G. **Distance education: A systems view of online learning**. [S.l.]: Cengage Learning, 2011.

MOREIRA, M. A. **Teorias de aprendizagem**. [S.l.]: Editora pedagógica e universitária São Paulo, 1999.

MURRAY, T. An overview of intelligent tutoring system authoring tools: Updated analysis of the state of the art. In: **Authoring tools for advanced technology learning environments**. [S.l.]: Springer, 2003. p. 491–544.

MYERS, I. B.; MCCAULLEY, M. H.; MOST, R. **Manual, a guide to the development and use of the Myers-Briggs type indicator**. [S.l.]: Consulting Psychologists Press, 1985.

NGUYEN, L. A new approach for modeling and discovering learning styles by using hidden markov model. **Global Journal of Human-Social Science Research**, v. 13, n. 4, 2013.

NUNES, I. B. **Noções de educação a distância**. 1992. Disponível em: <http://www.ibase.org.br/ined/ivonio1.html>. Acesso em: 22 out. 2017.

NWANA, H. S. Intelligent tutoring systems: an overview. **Artificial Intelligence Review**, Springer, v. 4, n. 4, p. 251–277, 1990.

OLIVEIRA, J. B. A.; CHADWICK, C. B. **Tecnologia educacional: teorias e instrução**. [S.l.]: Vozes, 1984.

OLIVEIRA, J. M. P.; FERNANDES, C. T. Arquitetura de adaptação em sistemas hipermídia adaptativos educacionais. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2002. v. 1, n. 1, p. 68–79.

OLIVEIRA, J. P. M. d. Adaptabilidade em sistemas de ensino a distância: o caso do projeto adaptaweb. **Ambientes Adaptativos—trilhando novos caminhos para a hipermídia**. Rio de Janeiro: Ciência Moderna, 2006.

OTERO, W. R. I. *et al.* **Educação a distância: desenvolvimento de habilidades cognitivas de alto nível em e-learning**. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2008.

ÖZPOLAT, E.; AKAR, G. B. Automatic detection of learning styles for an e-learning system. **Computers & Education**, Elsevier, v. 53, n. 2, p. 355–367, 2009.

PALAZZO, L. A. M. Sistemas de hipermídia adaptativa. **XXI Jornada de Atualização em Informática-Livro Texto**. Florianópolis, v. 1, p. 287–325, 2002.

PASHLER, H.; MCDANIEL, M.; ROHRER, D.; BJORK, R. Learning styles: Concepts and evidence. **Psychological science in the public interest**, SAGE Publications Sage CA: Los Angeles, CA, v. 9, n. 3, p. 105–119, 2008.

PASK, G. Styles and strategies of learning. **British journal of educational psychology**, Wiley Online Library, v. 46, n. 2, p. 128–148, 1976.

PETRUSHIN, V. A. Hidden markov models: Fundamentals and applications. In: **Online Symposium for Electronics Engineer**. [S.l.: s.n.], 2000.

PINHEIRO, M. A. **Estratégias para o design instrucional de cursos pela internet: um estudo de caso**. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2002.

PRICE, L. Individual differences in learning: Cognitive control, cognitive style, and learning style. **Educational Psychology**, Taylor & Francis, v. 24, n. 5, p. 681–698, 2004.

PUGA, S. G. **Sistemas Hipermídia adaptativos para a educação baseada na web: uma visão semiótica**. Tese (Doutorado) — Universidade de São Paulo, 2008.

RABINER, L. R. A tutorial on hidden markov models and selected applications in speech recognition. **Proceedings of the IEEE**, Ieee, v. 77, n. 2, p. 257–286, 1989.

RABINER, L. R.; WILPON, J. G.; SOONG, F. K. High performance connected digit recognition using hidden markov models. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, IEEE, v. 37, n. 8, p. 1214–1225, 1989.

RAJPER, S.; SHAIKH, N. A.; SHAIKH, Z. A.; MALLAH, G. A. Automatic detection of learning styles on learning management systems using data mining technique. **Indian Journal of Science and Technology**, v. 9, n. 15, 2016.

RAWSON, K.; STAHOVICH, T. F.; MAYER, R. E. Homework and achievement: Using smartpen technology to find the connection. **Journal of Educational Psychology**, American Psychological Association, v. 109, n. 2, p. 208, 2017.

REID, J. M. **Understanding learning styles in the second language classroom**. [S.l.]: Prentice Hall Regents, 1998.

RIBEIRO, P.; ASSIS, L.; VIVAS, A.; PITANGUI, C. Detecção de estilos de aprendizagem utilizando média móvel exponencialmente ponderada. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2017. v. 28, n. 1, p. 1247.

RODRIGUES, L. H. S.; VIVAS, A.; ASSIS, L.; PITANGUI, C.; FALCI, S. Uso de lógica fuzzy na seleção de estratégias de aprendizagem. **XXVII Simpósio Brasileiro de Informática na Educação**, 2016.

ROSÁRIO, J. d. A. d. *et al.* **Estilos de aprendizagem de alunos de engenharia química e engenharia de alimentos da ufsc: O caso da disciplina de análise e simulação de processos**. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2006.

ROSENBERG, M. J. E-learning: estratégias para a transmissão do conhecimento na era digital. **São Paulo: Makron Brooks**, 2001.

RUSSELL, S.; NORVIG, P. Artificial intelligence: a modern approach. **Prentice-Hall, Englewood Cliffs**, v. 25, 1995.

SABA, F. Distance education theory, methodology, and epistemology: A pragmatic paradigm. **Handbook of distance education**, v. 1, 2003.

SALAZAR, L.; ASSIS, L.; VIVAS, A.; PITANGUI, C.; FALCI, S. Detecção de estilos de aprendizagem em ambientes virtuais de aprendizagem utilizando redes bayesianas. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2017. v. 28, n. 1, p. 1247.

SANTOS, R. d. "jogos de empresas" aplicados ao processo de ensino e aprendizagem de contabilidade. **Revista Contabilidade & Finanças**, SciELO Brasil, v. 14, n. 31, p. 78–95, 2003.

SENA, E.; VIVAS, A.; ASSIS, L.; PITANGUI, C. Proposta de uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov e fsm. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2016. v. 27, n. 1, p. 1126.

SENECHAL, A. C. L. Análise e pré-processamento de dados utilizando técnicas de mineração de dados educacionais para o Moodle. 2013.



SHERRON, G. T.; BOETTCHER, J. V. **Distance learning: The shift to interactivity**. [S.l.]: CAUSE Boulder, CO, 1997. v. 17.

SILVA, D. M. d. **O impacto dos estilos de aprendizagem no ensino de contabilidade na FEA-RP/USP**. Tese (Doutorado) — Universidade de São Paulo, 2006.

SILVA, J. C. C.; PITANGUI, C. G.; VIVAS, A.; ASSIS, L. Uma nova abordagem para sistemas adaptativos e inteligentes utilizando dynamic scripting. **Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação**, v. 1, n. 8, 2018.

SILVA, L. L. V. **Estilos e estratégias de aprendizagem de estudantes universitários**. Tese (Doutorado) — Universidade de São Paulo, 2012.

SMYTH, P. Hidden markov models for fault detection in dynamic systems. **Pattern recognition**, Elsevier, v. 27, n. 1, p. 149–164, 1994.

SOLOMAN, B. A.; FELDER, R. M. **Index of Learning Styles Questionnaire**. 1991. Disponível em: <https://www.webtools.ncsu.edu/learningstyles/>. Acesso em: 03/10/2017.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning : An Introduction**. [S.l.]: MIT Press, 1998.

TAJRA, S. F. **Informática na Educação: novas ferramentas pedagógicas para o professor na atualidade**. [S.l.]: Érica, 2011.

TSIRIGA, V.; VIRVOU, M. A framework for the initialization of student models in web-based intelligent tutoring systems. **User Modeling and User-Adapted Interaction**, Springer, v. 14, n. 4, p. 289–316, 2004.

VAZ, D.; ZANELLA, R.; ANDRADE, S. Ambientes virtuais: Uma nova ferramenta de ensino. **Revista iTEC**, v. 1, n. 1, p. 8–12, 2010.

VEENMAN, M. V.; PRINS, F. J.; VERHEIJ, J. Learning styles: Self-reports versus thinking-aloud measures. **British Journal of Educational Psychology**, Wiley Online Library, v. 73, n. 3, p. 357–372, 2003.

VICARI, R. M.; GIRAFFA, L. M. Fundamentos dos sistemas tutores inteligentes. **Sociedades artificiais: a nova fronteira da inteligência das máquinas**. Porto Alegre: Bookman. ISBN, p. 85–363, 2003.

VILLAYERDE, J. E.; GODOY, D.; AMANDI, A. Learning styles' recognition in e-learning environments with feed-forward neural networks. **Journal of Computer Assisted Learning**, Wiley Online Library, v. 22, n. 3, p. 197–206, 2006.

WAALKENS, M.; ALEVEN, V.; TAATGEN, N. Does supporting multiple student strategies lead to greater learning and motivation? investigating a source of complexity in the architecture of intelligent tutoring systems. **Computers & Education**, Elsevier, v. 60, n. 1, p. 159–171, 2013.

WIER, L. M. **Mary Cover Jones: uma pioneira na terapia comportamental**. 2005. Disponível em: <http://abpmc.org.br/arquivos/publicacoes/14053681755ea5046c77a.pdf>. Acesso em: 17 out. 2017.

WU, H.; HOUBEN, G.-J.; BRA, P. D. Supporting user adaptation in adaptive hypermedia applications. In: **Proceedings InfWet2000. Rotterdam, the Netherlands**. [S.l.: s.n.], 2000.



YANG, L.; WIDJAJA, B.; PRASAD, R. Application of hidden markov models for signature verification. **Pattern recognition**, Elsevier, v. 28, n. 2, p. 161–170, 1995.

YANNIBELLI, V.; GODOY, D.; AMANDI, A. A genetic algorithm approach to recognise students' learning styles. **Interactive Learning Environments**, Informa UK Limited, v. 14, n. 1, p. 55–78, apr 2006. Disponível em: <https://doi.org/10.1080/10494820600733565>.

